Universidade do Minho
Escola de Engenharia

João Pedro Figueiredo Bravo de Faria

Sistema de visão por computador para detecção de variações de cor em folhas de madeira.

Sistema de visão por computador para detecção de variações de cor em folhas de madeira.
João Pedro F. Bravo de Faria
UMinho | 2007

Novembro de 2007

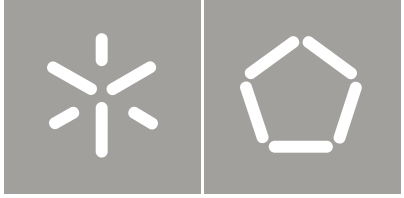

Universidade do Minho
Escola de Engenharia

João Pedro Figueiredo Bravo de Faria

Sistema de visão por computador para detecção de variações de cor em folhas de madeira.

Tese de Mestrado
Mestrado Integrado em Engenharia Electrónica Industrial e Computadores.

Trabalho efectuado sob a orientação do
Professor Manuel João Ferreira
e co-orientação da
Mestre Teresa Martins

Novembro de 2007

DECLARAÇÃO

Nome

João Pedro Figueiredo Bravo de Faria

Endereço electrónico: jbravofaria@gmail.com

Número do Bilhete de Identidade: 12112761

Título da dissertação

Sistema de visão por computador para detecção de variações de cor em folhas de madeira.

Orientador:

Prof. Manuel João Ferreira

Ano de conclusão: 2007

Designação do Mestrado ou do Ramo de Conhecimento do Doutoramento:

Mestrado Integrado em Engenharia Electrónica Industrial e Computadores

É AUTORIZADA A REPRODUÇÃO PARCIAL DESTE TRABALHO APENAS PARA EFEITOS DE INVESTIGAÇÃO, MEDIANTE DECLARAÇÃO ESCRITA DO INTERESSADO, QUE A TAL SE COMPROMETE.

Universidade do Minho, ____/____/_____

Assinatura: _____

Abstract:

This thesis describes the development of a project based in Fuzzy Logic applied to color histograms for color grading wood boards. During this project Fuzzy Min-Max method with triangle and bell membership functions and Fuzzy Grammar were implemented in order to decide the best approach to this problem. The systems evaluation was based in its accuracy and training method. This system performs image matching where images given as training samples will be used to define the classes that determine the several wood board color intervals. It's important to mention that the choice of the training samples is directly related with the system accuracy and the processing time until it matches the images. By the end of this project this system is capable of classify an image by its color in order to group wood boards with the same tonality in a short period time.

Resumo

Este projecto surge no âmbito do controlo de qualidade na indústria da madeira. Pretende-se assim recorrer a um sistema de visão assistida por computador para proceder à inspecção de folhas de madeira. Durante o seu desenvolvimento foram investigadas alternativas para a sua implementação de modo a seleccionar uma abordagem que permitisse executar a tarefa pretendida tendo em conta a sua eficácia, fiabilidade e tempo de processamento.

O aspecto fundamental da inspecção levada a cabo por este sistema consiste na classificação de folhas de madeira quanto ao seu tipo e classe de cor, e posteriormente na detecção de variações de tonalidade em porções de menor dimensão da mesma folha de madeira.

Tendo em conta as características das diferentes abordagens encontradas que permitiriam implementar o projecto em causa, a Lógica Difusa foi considerada a mais apropriada para dar continuação a este projecto uma vez que permite a constituição de um sistema automático, com uma implementação relativamente simples e reduzida carga de processamento. Foram analisados diversos espaços de cor de modo a determinar as características a serem extraídas da imagem que permitissem diferenciar os diferentes tipos de madeira e variações de tonalidade nos mesmos, bem como diferentes abordagens possíveis relacionadas com a lógica difusa nomeadamente a representação das funções pertença e sistemas de inferência.

Outros aspectos como uma filtragem da imagem, dimensão da janela de análise durante o varrimento da mesma e parametrização relacionada com a lógica difusa encontram-se também descritos de modo a justificar as opções tomadas durante a elaboração deste projecto.

Palavras-Chave: Lógica Difusa, inspecção visual, visão por computador, Min-Max.

Índice

Abstract:	i
Resumo	iii
Índice	v
Índice de Figuras	vii
Índice de Tabelas	xi
1. Introdução	1
1.1. Enquadramento	1
1.2. Estado da Arte	2
1.3. Objectivos	3
1.4. Estrutura da Tese	5
2. Descrição dos métodos	7
2.1. Espaços de Cor	8
2.2. Lógica Difusa	16
2.2.1 Representação das funções pertença	18
2.2.2 Sistemas de inferência	26
2.2.3 Min-Max	26
2.2.4 Max-Sum	27
2.2.5 Gramática Difusa	28
2.2.6 Parametrização das aproximações.	31
2.2.7 Outras considerações	34
3. Apresentação e discussão dos resultados	39
3.1. Métodos de Teste e Análise de Resultados	39
3.1.1 Lógica Difusa aplicada na análise global da imagem	41
3.1.2 Lógica Difusa aplicada na análise de porções da imagem.	42
4. Conclusões	55
Bibliografia	59
Referências Gráficas	63
Lista de Siglas e Acrónimos	65
Anexos	67
I. Anexo 1 – Amostras de folha de madeira disponíveis.	69

Índice de Figuras

Figura 1 – Modelo do possível *setup* em ambiente industrial 8
Figura 2 – Representação do cubo do espaço de cor RGB (a), e modelo aditivo do espaço de cor RGB (b). 9
Figura 3 – Representação do espaço de cor XYX 10
Figura 4 – Representação do espaço de cor HSV (a) e escala de *Hue* do mesmo (b). 12
Figura 5 – Representação do espaço de cor HSL sob a forma de duplo cone (a) e sob a forma esférica (b). 13
Figura 6 – Representação do espaço de cor CIE L*a*b*. 14
Figura 7 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos diferentes canais que a caracterizam. 17
Figura 8 – Algoritmo de recolha dos parâmetros dos histogramas para aproximações recorrendo a triângulos. 18
Figura 9 – Aplicação utilizada para recolha dos valores dos histogramas. 19
Figura 10 – Aproximações ao histograma real da amostra 1b1 recorrendo a triângulos. 20
Figura 11 – Aproximações ao histograma real da amostra 6a3 recorrendo a triângulos. 20
Figura 12 – Representação da função sino e significado dos seus parâmetros. 21
Figura 13 – Aproximações ao histograma real da amostra 1b1 recorrendo a funções sino. 22
Figura 14 – Aproximações ao histograma real da amostra 6a3 recorrendo a funções sino. 22
Figura 15 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos canais que a caracterizam depois de submetidos a uma filtragem de uma iteração. 23
Figura 16 – Aproximações ao histograma real da amostra 1b1 recorrendo a funções sino depois de submetidas a uma filtragem de uma iteração. 24

Figura 17 – Aproximações ao histograma real da amostra 6a3 recorrendo a funções sino depois de submetidas a uma filtragem de uma iteração. 24
Figura 18 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos canais que a caracterizam depois de submetidos a uma filtragem de cinco iterações. 25
Figura 19 – Representação do funcionamento do método de inferência Min-Max de gramática difusa. 27
Figura 20 - Representação do funcionamento do método de inferência Sum-Max de gramática difusa. 28
Figura 21 – Exemplo de gramática difusa recorrendo a seis primitivas para descrever todo o universo difuso. 28
Figura 22 – Representação do grau de pertença de cada primitiva para cada canal em função características extraídas do histograma de uma amostra considerando um universo de 15 primitivas. 29
Figura 23 – Algoritmo implementado para o uso de gramática difusa. 30
Figura 24 – Algoritmo implementado para treino recorrendo a funções sino com dois parâmetros fixos. 31
Figura 25 – Comparação entre histograma de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com dois parâmetros fixos. 32
Figura 26 – Algoritmo implementado para treino recorrendo a funções sino com um parâmetro fixo. 32
Figura 27 – Comparação entre histogramas de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com um parâmetro fixo. 33
Figura 28 – Comparação entre histogramas de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com um parâmetro fixo. 34
Figura 29 – Algoritmo implementado para o processo de avaliação das amostras. 35
Figura 30 – Representação dos deslocamentos da janela relativamente à posição anterior durante o processo de varrimento da imagem. 36
Figura 31 – Representações das porções submetidas a avaliação durante o varrimento da imagem. 37
Figura 32 – Aspecto da aplicação desenvolvida para teste dos diferentes métodos. 40
Figura 33 – Amostra 2c2 (a), respectiva segmentação (b) e amostra 4a3 (c). 45

Figura 34 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=100 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades. 46
Figura 35 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 33. 47
Figura 36 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=200 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades. 48
Figura 37 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 35. 49
Figura 38 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=400 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades. 50
Figura 39 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 38. 50

Índice de Tabelas

TABELA I - Designação e função dos termos linguísticos implementados para efeito de teste do método recorrendo a gramática difusa. 41
TABELA II - Percentagem de erro nos diferentes métodos abordados com D=100 43
TABELA III - Percentagem de erro nos diferentes métodos abordados com D=200 44
TABELA IV - Percentagem de erro nos diferentes métodos abordados com D=400 45
TABELA V - Resultados sem erro em qualquer das abordagens comparativamente ao número de amostras disponíveis para cada tipo de madeira 48
TABELA VI - Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=100. 51
TABELA VII - Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=200. 52
TABELA VIII - Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=400. 53

1. Introdução

1.1. Enquadramento

Depois do abate, uma árvore passa por uma série de transformações até que seja obtido o produto final. Independentemente do produto pretendido a madeira deve sempre ser submetida a um processo de secagem de modo a evitar variações de dimensão ou deformações, obter uma maior resistência e evitar a putrefacção. Este processo pode ser feito de modo natural – onde a madeira apenas é exposta ao ar – apresentando os inconvenientes de necessitar de grandes áreas ao ar livre, da utilização da madeira não pode ser imediata - uma vez que este procedimento tende a ser demorado - e da madeira ficar exposta a fungos e insectos durante o período de secagem. Por outro lado pode proceder-se a uma secagem artificial – recorrendo a estufas ou ventilação mecânica – que no entanto tende a ser um processo muito dispendioso e por vezes, caso o sistema não esteja bem dimensionado a madeira pode perder algumas das suas características como a flexibilidade, provocar alterações de cor e por vezes, em alguns tipos de madeira, o aparecimento de manchas [1]. Torna-se assim necessário proceder a uma classificação da madeira de modo a poder orientar a sua utilização de acordo com a qualidade, e por vezes tendo em conta a sua textura e tonalidade.

A inspecção de componentes e/ou produtos apresenta um papel cada vez mais importante dentro do sector industrial, tanto para controlo de qualidade, bem como para selecção ou separação de componentes com diferentes características. Este tipo de trabalhos era efectuado por humanos e geralmente baseado em conhecimento empírico, mas com o desenvolvimento da tecnologia tornou-se possível, em outros sectores, recorrer a sistemas de visão assistida por computador para proceder a essa inspecção. Este tipo de sistemas consegue extrair características muitas vezes imperceptíveis aos humanos e fazê-lo de forma mais rápida e eficaz. Surge uma oportunidade de melhorar a qualidade dos produtos e aumentar a produção. É

importante também realçar que em muitos casos os custos de produção aumentam exponencialmente com o ponto em que os defeitos são detectados [2], sendo necessário por vezes proceder a vários estágios de inspecção visual, desde a matéria-prima até ao produto final.

1.2. Estado da Arte

Este projecto incide na inspecção visual de folhas de madeira sendo necessário ter em consideração diversos factores que podem afectar uma boa avaliação das características pretendidas. Esses factores são a localização do stock, que pode estar sujeito às condições atmosféricas afectando o seu aspecto. Assim como grau de humidade da madeira pode provocar variações na sua cor, fazendo com que madeira da mesma árvore possa assumir cores diferentes. Estes factores podem trazer inúmeros inconvenientes caso não tenham sido tidos em conta depois do processo de análise. Existem também outros factores externos que podem afectar o processo de avaliação, como a existência de sujidade ou resíduos deixados, como por exemplo por, autocolantes [3].

Além da sua cor e variação da mesma existem também características da própria madeira que podem ser sujeitas a avaliação como a textura e nós, podendo estas também variar com a espécie da madeira a ser analisada.

Já é possível encontrar na literatura diferentes abordagens para a inspecção visual de madeiras especialmente no que diz respeito à identificação de nós e variações de textura. As abordagens mais frequentes eram baseadas em *Self Organizing Maps* [4], também conhecidos como *Kohonen´s Maps*, Lógica Difusa [5] ou segmentação baseada na binarização da imagem através de valores recolhidos do histograma da mesma [6].

No que diz respeito à segmentação de uma imagem recorrendo a múltiplos *thresholds* baseados no histograma da mesma os pontos de *threshold* são obtidos através dos pontos vale e pontos de inflexão do histograma da imagem em tons de cinzento. Esses “pontos de inflexão eram examinados como candidatos para *threshold*“, pois pequenos defeitos, a nível de histograma, são por vezes confundidos com a madeira sã sem criar um máximo relativo que os identifique. Depois de obtidos os pontos de *threshold* a imagem é submetida a um processo de filtragem e a uma reavaliação dos pontos de modo a determinar quais os que irão evidenciar os defeitos. Este método revelou ser promissor no que diz respeito a nós, buracos e decaimento nos extremos da prancha de madeira, não sendo no entanto viável para análises de cor [6].

Os SOMs são encarados como uma combinação das vantagens da classificação supervisionada e classificação não supervisionada (da linguagem anglo-saxónica *supervised* e *unsupervised classification*, respectivamente) [4]. Entenda-se classificação supervisionada como um método de classificação em que é necessária a intervenção humana para a atribuição de amostras para cada característica ou classe, implicando um bom conhecimento do sistema, bem como das classes que o constituem; e classificação não supervisionada como a classificação das características de uma imagem baseada essencialmente em estatísticas extraídas da imagem sem recorrer a amostras de treino ou conhecimento prévio do problema em causa. Geralmente aplicações que recorrem a SOMs apresentam um interface bastante intuitivo, uma vez que na fase onde se dá o processo de etiquetagem das amostras, quando os dados são apresentados ao utilizador encontram-se, agrupados de acordo com as suas características. Assim sua percepção e o processo de etiquetagem torna-se mais simples, rápido pois as etiquetas são atribuídas a grupos e não necessariamente a amostras isoladas. Os resultados obtidos recorrendo a este tipo método são bastante aceitáveis, no entanto a sua carga de processamento é relativamente elevada e para o seu desenvolvimento e implementação são necessários bons conhecimentos das técnicas usadas neste tipo de sistemas.

Outro dos métodos que despertou especial interesse foi a lógica difusa uma vez que esta pode ser encarada com uma ”tentativa de lidar com conhecimento vago” [7]. Neste tipo de avaliações as respostas não podem ser traduzidas simplesmente como verdadeiras ou falsas. A Lógica Difusa permite obter um grau de abstracção ideal para este tipo de classificações. É importante realçar que a sua implementação é relativamente simples e o peso de processamento não é muito significativo. No entanto o processo de ajuste pode ser bastante moroso uma vez que este método baseia-se fundamentalmente no conhecimento empírico do processo pretendido sendo assim necessário conhecimento prévio do sistema a ser implementado e neste caso das características a serem analisadas.

1.3. Objectivos

Depois de serem extraídas folhas de madeira do tronco é necessário proceder a uma inspecção para garantir um correcto agrupamento das mesmas por classes de tonalidade, bem como definir o grau de qualidade da folha em causa. Esta separação é fundamental para obter uniformidade do produto acabado.

O processo de inspecção é efectuado por operadores especializados ao longo das fases de produção da folha – unidade de secagem, unidade de controlo dimensional e

unidade de preparação da folha. Por vezes os operadores podem não detectar algumas das falhas, por isso pretende criar-se um sistema capaz de proceder à classificação destas folhas por classes de tonalidade e que consiga atribuir um grau de qualidade à folha em questão. É importante mencionar que este tipo de sistema não proporciona só uma maior eficiência no que diz respeito ao controlo de qualidade, mas pode também ser traduzido num aumento de produtividade e custos cada vez menores atribuídos ao processo de produção.

No ponto anterior foram apresentados alguns métodos aplicados actualmente à inspecção visual de madeiras, no entanto alguns destes métodos apesar de apresentarem bons resultados para determinado tipo de defeitos não conseguem abranger a gama de características que se pretende avaliar, definida para este projecto. Note-se que é muito importante escolher o método mais adequado tendo em conta a sua eficiência e robustez mas também o seu peso de processamento uma vez que a análise tem de ser capaz de acompanhar a capacidade de produção do sistema actualmente implementado.

Dado que a Lógica Difusa apresenta as características necessárias para a realização deste projecto foi determinada como o método a ser implementado uma vez que esta apresenta flexibilidade suficiente no sistema de avaliação, associada a um baixo peso de processamento capazes de satisfazer os requisitos industriais.

Para a implementação deste sistema será necessário considerar diversos aspectos relativamente à Lógica Difusa: a forma usada para a representação das funções pertença – triangular, trapezoidal, gaussiana, sino – e o método de inferência - MinMax, MaxMin, MaxProduto, MinMin, MaxMedia, MaxMax, Soma dos produtos [8]. Outro factor a ser considerado é o processo de criação das classes, que deverá ser suficientemente fléxivel para que um operador possa inserir uma nova classe sem grandes conhecimentos acerca do sistema implementado e sem que isso seja traduzido numa perda de tempo significativa.

É necessário também considerar quais as características a serem avaliadas, em específico, determinar qual, ou quais os espaços de cor mais adequados para esta avaliação. Apesar de se estar a considerar que o sistema de visão apresentará uma grande robustez, e para este efeito uma iluminação constante, é necessário prever factores como a idade das lâmpadas que poderão afectar a sua luminosidade com o passar do tempo. É preciso então tentar minimizar este problema considerando espaços de cor que consigam garantir alguma independência deste factor.

1.4. Estrutura da Tese

Neste documento pretende apresentar-se os passos seguidos e os aspectos considerados na implementação do projecto. Para isso, depois de ponderar sobre os métodos utilizados até agora para projectos de características semelhantes procedeu-se à selecção da abordagem mais adequada, tendo em conta a aptidão para desempenhar a tarefa pretendida como a carga de processamento necessária para esse mesmo processo. No ponto **Descrição dos métodos** são apresentados os diferentes espaços de cor que serão a base para este projecto. Da sua análise irá resultar a escolha de um ou mais espaços que permitam diferenciar os diferentes tipos de madeira e variações de tonalidade nos mesmos. Também são apresentadas possíveis abordagens para solucionar este problema de acordo com o método escolhido para executar a análise das características recolhidas da imagem, bem como diversos factores que foram tidos em conta de modo a determinar a melhor estratégia dentro das várias abordagens apresentadas – tais como variantes dos métodos e parametrização dos mesmos. Posteriormente os resultados obtidos dos métodos considerados de maior relevância são apresentados no capítulo **Apresentação de discussão dos resultados**. Neste capítulo é possível visualizar estatísticas e imagens resultantes da segmentação de amostras de folha de madeira de modo a fundamentar as escolhas tomadas no decorrer deste projecto. Para finalizar são apresentadas **Conclusões** obtidas durante o desenvolvimento do projecto bem como hipóteses pensadas para melhorar os aspectos apresentados para este sistema.

2. Descrição dos métodos

Dos métodos referidos no capítulo anterior foi necessário estabelecer uma estratégia a seguir bem como optar pelas diferentes variantes de cada método. Assim procedeu-se a um estudo dos espaços de cor disponíveis na biblioteca OpenCV de modo a determinar uma solução robusta para a identificação das folhas de madeira de acordo com as suas características de cor. Posteriormente procedeu-se à selecção da abordagem de lógica difusa, bem como à investigação de diversos parâmetros que poderiam influenciar o processo de avaliação. Como já foi referido a Lógica difusa é um processo que se baseia fundamentalmente no conhecimento empírico do operador. Torna-se assim necessário executar testes meticulosamente de modo a verificar as alterações produzidas pela manipulação dos diferentes parâmetros.

É necessário ter em conta também que este tipo de processos tem de apresentar uma elevada fiabilidade, pois ao recorrer-se a sistemas de inspecção visual assistida por computador para o controlo de qualidade deve garantir-se que estes não irão introduzir mais incertezas no processo de produção. Torna-se então necessário garantir que o sistema implementado, na pior das hipóteses, será tão fiável como uma avaliação levada a cabo por um operador e que a implementação deste tipo de sistemas não vai introduzir nenhuma limitação em termos de velocidade ao sistema de produção, pois pretende-se não só obter um controlo de qualidade mais rigoroso mas também aumentar a capacidade de produção do mesmo.

É também necessário considerar diversos factores relativamente ao *setup* do sistema. De modo a evitar sombras ou reflexos, para garantir uma boa qualidade da imagem a ser analisada, é imperativo escolher cuidadosamente o tipo de câmara e iluminação a ser utilizada, bem como a disposição das mesmas. O sistema industrial deverá consistir numa câmara de CCD linear posicionada por cima de uma tela transportadora e uma lâmpada fluorescente de alta frequência (Figura 1). Foi considerada a necessidade de adicionar um sistema que permitisse manter as folhas de madeira esticadas. Dadas as dimensões das folhas de madeira, aproximadamente 300x2000mm e espessura inferior a 1mm, por vezes verifica-se uma ondulação das mesmas que poder resultar em erros ou má qualidade das imagens durante o

processo da sua aquisição. Esse sistema poderá consistir num conjunto de rolos posicionados antes e depois da fase de aquisição, em que a folha de madeira, ao passar entre eles, será ligeiramente esticada, tentando assim minimizar-se o efeito da ondulação.

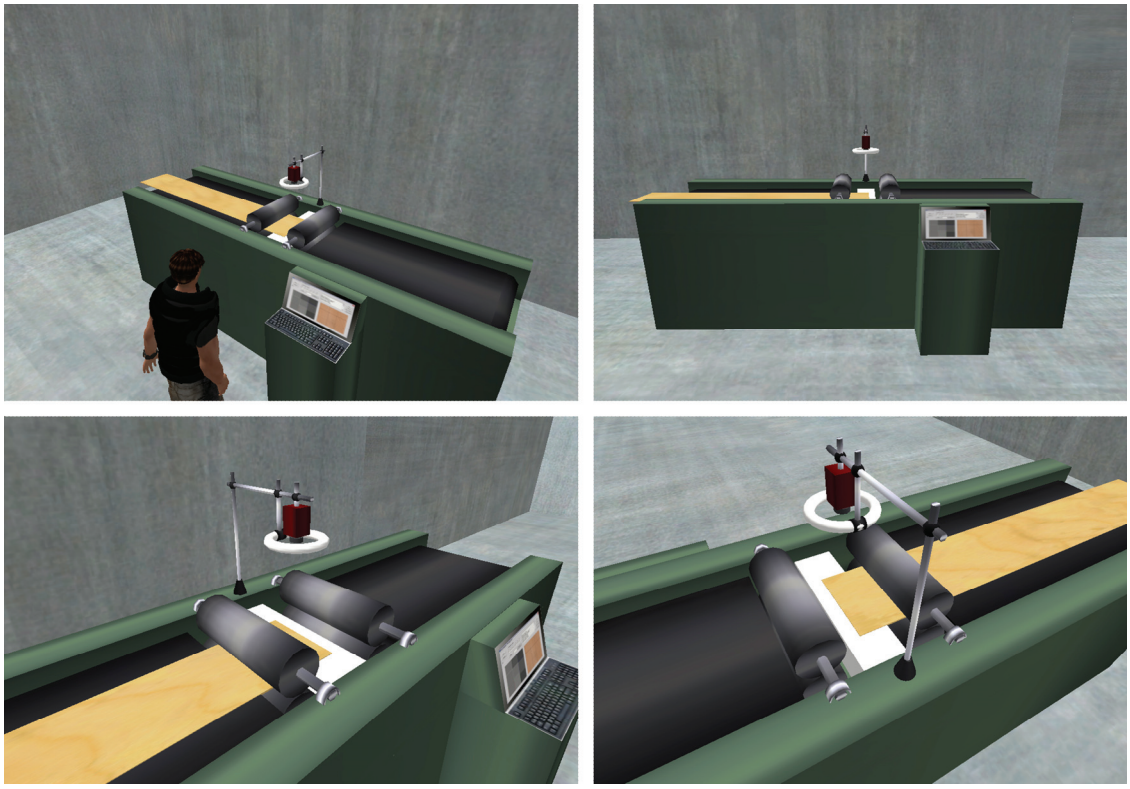

Figura 1 – Modelo do possível *setup* em ambiente industrial

Para efeitos de simulação, de modo a validar os algoritmos e a aproximação global feita em laboratório irá recorrer-se a imagens obtidas a partir de um *scanner*.
As abordagens estudadas consideradas relevantes no âmbito deste projecto encontram-se referidas nos pontos que se seguem.

2.1. Espaços de Cor

Dentro da perspectiva moderna, um modelo de cor tem como uma das suas características a especificação da cor de uma luz ou superfície numa mistura de atributos. Estes atributos podem ser cores primárias, atributos baseados na teoria dos três estímulos, valores de *Hue* únicos [9].
No âmbito deste projecto torna-se necessário encontrar um espaço de cor que permita identificar cores semelhantes de um modo suficientemente robusto de modo a poder estabelecer variações das mesmas nas folhas de madeira. Um dos pontos que foi tido

em conta durante a análise dos espaços foi que a iluminação poderia apresentar variações com a idade da luminária e assim os espaços escolhidos deveriam prever este factor.

Os espaços de cor disponíveis na biblioteca OpenCV são apresentados a seguir, juntamente com uma breve descrição dos seus atributos e características mais relevantes.

RGB

O espaço de cor RGB assenta no facto do sistema de processamento de cor do olho humano ser baseado na amostragem das faixas vermelha (red), verde (green) e azul (blue) do espectro visível [10]. Surge assim uma representação tridimensional de um cubo associado a um sistema de eixos, em que os seus pontos interiores correspondem à mistura de diferentes variações da cor associada a cada eixo. Este espaço de cor assenta na teoria dos três estímulos (na linguagem Anglo-Saxónica referido como Tristimulus Color Theory) que é baseada na forma como o nosso cérebro interpreta as cores. Isto é, o olho humano apresenta dois tipos de sensores, denominados de bastonetes e cones. Existem três tipos de cones, cada um sensível a luz vermelha, verde ou azul. Cada cone indica ao cérebro a quantidade de estímulo recebida. Assim criou-se uma forma de descrever as cores através de valores numéricos relacionados com a sensibilidade do olho humano às faixas de vermelho, verde e azul do espectro visível [11]. Na linha que une a origem do nosso referencial (correspondendo à cor preta) ao ponto que representa o valor máximo que cada componente de cor pode tomar (correspondendo à cor branca) é-nos apresentada a escala cinza, ou seja, cada vez que as componentes R, G e B apresentam o mesmo valor, obtemos um diferente tom de cinzento [10, 12, 13].

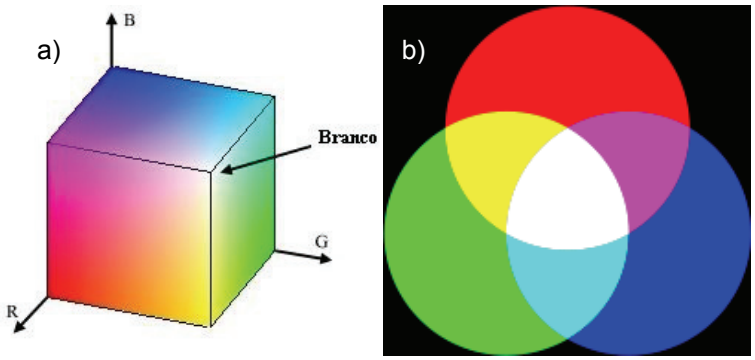

Figura 2 – Representação do cubo do espaço de cor RGB (a), e modelo aditivo do espaço de cor RGB (b).

XYZ

O sistema de cores CIE XYX é um sistema aditivo que descreve as cores através de três cores primárias que não correspondem a cores visíveis mas garantindo que as suas componentes de cor são positivas, permitindo assim a representação de todos os comprimentos de onda de luz visível. Este sistema foi especialmente desenhado para que o parâmetro Y seja a quantidade de brilho, ou luminosidade (da linguagem Anglo-Saxónica *luminance*), de uma dada cor. A cromaticidade (da linguagem Anglo-Saxónica *cromaticity*) dessa cor é especificada através dos parâmetros x e y, sendo estes dois dos três valores normalizados em função da teoria dos três estímulos dos valores X, Y e Z [13, 14, 15].

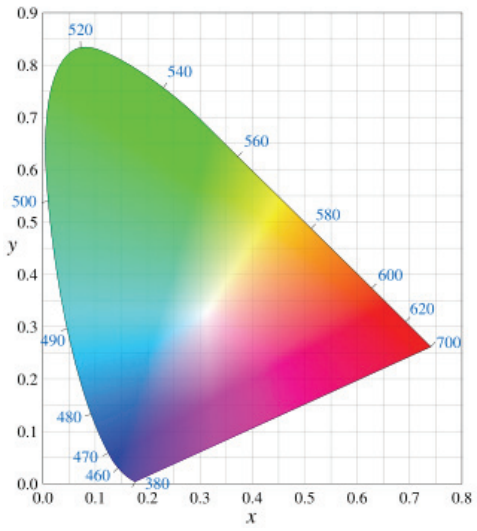

Figura 3 – Representação do espaço de cor XYX

A transformação de RGB para XYZ pode ser feita através das Equações 2.1 a 2.5.

$$x = \frac{X}{X+Y+Z} \qquad \textit{Equação 2. 1}$$

$$y = \frac{Y}{X+Y+Z} \qquad \textit{Equação 2. 2}$$

$$z = \frac{Z}{X+Y+Z} = 1-x-y \qquad \textit{Equação 2. 3}$$

Os parâmetros X e Z podem ser obtidos através dos valores de cromaticidade x e y e do parâmetro Y.

$$X = \frac{Y}{y}x \qquad \textit{Equação 2. 4}$$

$$Z = \frac{Y}{y}(1-x-y) \qquad \textit{Equação 2. 5}$$

YCrCb

YCrCb não é totalmente um espaço de cor, mas uma forma de codificar a informação RGB. Assim o YCrCb só é previsível se estivermos a recorrer aos pigmentos RGB ou se for executada uma conversão para estes pigmentos [16]. Neste sistema Y representa o brilho, Cr a cromaticidade vermelha e Cb a cromaticidade azul, sendo a conversão possível através das Equações 2.6 a 2.8.

$$Y' = Kr \times R' + (1 - Kr - Kb) \times G' + Kb \times B' \qquad \textit{Equação 2. 6}$$

$$Cb = Pb = \frac{1}{2} \times \frac{B' - Y'}{1 - Kb} \qquad \textit{Equação 2. 7}$$

$$Cr = \mathrm{Pr} = \frac{1}{2} \times \frac{R' - Y'}{1 - Kr} \qquad \textit{Equação 2. 8}$$

Sendo Kb e Kr constantes predefinidas obtidas através do espaço RGB. Os valores de R, G e B afectados por plicas indicam que estes foram afectados por correcções de gama. Normalmente estes valores passam a ser representados por intervalos compreendidos entre 0 e 1, onde 0 indica a mínima intensidade e 1 a máxima. O valor resultante Y tomará valores entre 0 e 1, e Cr e Cb estarão compreendidos entre -0.5 e +0.5 [10, 16, 17].

HSV

O espaço de cor HSV resulta, tal como nos espaços referidos anteriormente, na combinação de três componentes: *Hue*; *Saturation* e *Value*, e consiste numa transformação não linear do espaço de cor RGB (Figura 4). *Hue* corresponde ao comprimento de onda dominante do espectro e apresenta-se num intervalo entre 0º e 360º na maioria das aplicações, mas algumas vezes reduzido a 180, como é o caso do OpenCV no intuito de fazer coincidir o intervalo com o número de bits atribuído a cada canal. Cada valor de *Hue* corresponde a uma cor diferente, por exemplo, e

considerando que varia entre 0 e 360, o valor 0 corresponde a vermelho, 120 a um tom de verde, 240 a um tom de azul, como pode ser facilmente observado na Figura 4b. *Saturation* encontra-se relacionado com a intensidade da cor, onde 0 indica a ausência de cor e toma o valor máximo quando a cor é pura. *Value* está relacionado com o brilho [10, 18]. Quando o seu valor é nulo obtém-se preto, independentemente do valor de H e S. Quando S toma o valor de 0 obtém-se um tom de cinzento diferente consoante o valor de V. O HSV apresenta também a vantagem da sua representação se assemelhar à percepção humana.

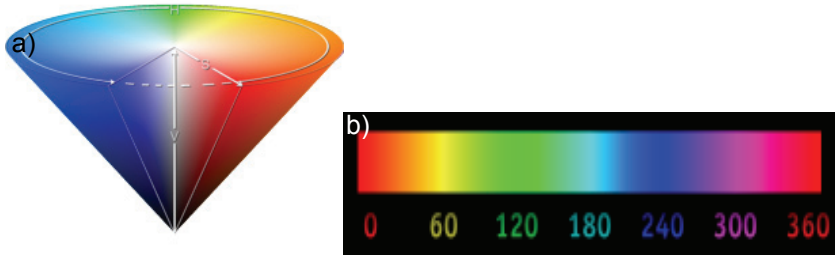

Figura 4 – Representação do espaço de cor HSV (a) e escala de *Hue* do mesmo (b).

A conversão de RGB para HSV pode ser obtida através das Equações 2.9 a 2.13.

$$r = \frac{R}{255}; g = \frac{G}{255}; b = \frac{B}{255}; \qquad \textit{Equação 2. 9}$$

$$V = \max(r, g, b) \qquad \textit{Equação 2. 10}$$

$$S = \begin{cases} 0, & if\,(V = 0) \\ V - \min(r, g, b), & otherwise \end{cases} \qquad \textit{Equação 2. 11}$$

$$H = \begin{cases} (G - B) \times \frac{60}{S}, & if\,(V = R) \\ 180 + (B - R) \times \frac{60}{S}, & if\,(V = G) \\ 240 + (R - G) \times \frac{60}{S}, & if\,(V = B) \end{cases} \qquad \textit{Equação 2. 12}$$

$$if\,(H < 0 \quad then \quad H = H + 360) \qquad \textit{Equação 2. 13}$$

HSL

O HSL, também conhecido por HSI é um espaço de cor que tal como o HSV recorre ao *Hue* e *Saturation* como atributos de dois dos canais, mas a sua diferença reside no facto que em vez do *Value* temos a Luminosidade/Intensidade (da linguagem Anglo-

Saxónica "*Lightness* (*Luminance*, *Luminosity*)/*Intensity*")[19], deixando de ser representado por um cone para passar a ter a representação de um duplo cone, cilindro, ou mesmo uma esfera [10, 19] (Figura 5).

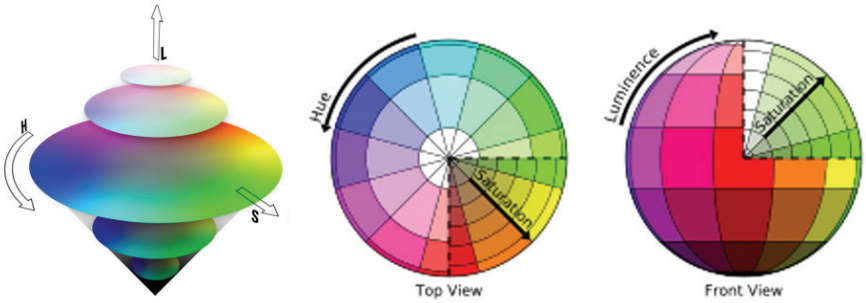

Figura 5 – Representação do espaço de cor HSL sob a forma de duplo cone (a) e sob a forma esférica (b).

O espaço de cor HSL pode ser obtido a partir do RGB recorrendo às Equações 2.14 a 2.18.

$$r = \frac{R}{255}; g = \frac{G}{255}; b = \frac{B}{255}; \qquad \textit{Equação 2. 14}$$

$$MAX = \max(r,g,b); MIN = (r,g,b) \qquad \textit{Equação 2. 15}$$

$$H = \begin{cases} undefined, & if\,(MAX = MIN) \\ 60 \times \dfrac{G-B}{MAX-MIN} + 0, & if\,(MAX = R \wedge G \geq B) \\ 60 \times \dfrac{G-B}{MAX-MIN} + 360, & if\,(MAX = R \wedge G < B) \\ 60 \times \dfrac{G-B}{MAX-MIN} + 120, & if\,(MAX = G) \\ 60 \times \dfrac{G-B}{MAX-MIN} + 240, & if\,(MAX = B) \end{cases} \qquad \textit{Equação 2. 16}$$

$$S \begin{cases} 0, & if\,(L = 0 \vee MAX = MIN) \\ \dfrac{MAX-MIN}{MAX+MIN} - \dfrac{MAX-MIN}{2 \times L} & if\,(0 < L \leq \dfrac{1}{2}) \\ \dfrac{MAX-MIN}{2-(MAX+MIN)} - \dfrac{MAX-MIN}{2-2 \times L} & if\,(L > \dfrac{1}{2}) \end{cases} \qquad \textit{Equação 2. 17}$$

$$L = \frac{1}{2} \times (MAX + MIN)$$ *Equação 2. 18*

CIE L*a*b*

Este é um espaço baseado no CIE XYZ que descreve todas as core perceptíveis ao olho humano e é independente do dispositivo em uso [20, 21, 22]. Apresenta como canais L* representado a *Luminance*, a* onde valores negativos indicam verde e positivos vermelho, e o canal b* que apresenta azul para valores negativos e amarelo para positivos. Quando L* é igual a 0 obtemos preto, mas note-se que o preto associa-se não a uma sensação de cor mas como a ausência de luz ou reflexo numa superfície [9], para L* igual a 100 a cor apresentada será branco [10, 23]. Isto surge do facto de se ter a dimensão luminosidade perpendicular ao plano que representa a cromaticidade, ou *Hue*. Assim o CIE L*a*b* mede a *chroma*, que consiste no conteúdo cromático de uma cor, independentemente da sua luminosidade e no plano a* b* não é apresentada a saturação da mesma. Um estudo que pretendia apurar a capacidade de diferentes espaços fazerem corresponder diferentes cores visualizadas em diferentes níveis de luminosidade, o CIE L*a*b* apresentou bons resultados contra modelos bem mais complexos, e em alguns casos os resultados eram equivalentes aos melhores. [9].

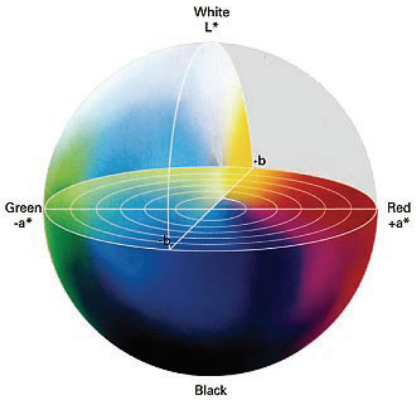

Figura 6 – Representação do espaço de cor CIE L*a*b*.

A transformação de RGB para o espaço de cor CIE L*a*b* pode ser obtida através das Equações 2.19 a 2.23.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$ *Equação 2. 19*

$$L^* = 116 \times \left(f\left(\frac{Y}{Y_0}\right) - \frac{16}{116} \right)$$ *Equação 2. 20*

$$a^* = 500 \times \left(f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right) \right)$$ *Equação 2. 21*

$$b^* = 200 \times \left(f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right) \right)$$ *Equação 2. 22*

$$f(v) = \begin{cases} v^{\frac{1}{3}} & v > 0.008856 \\ 7.787 \times v + \frac{16}{116} & v \le 0.008856 \end{cases}$$ *Equação 2. 23*

CIE L*u*v

Tal como o CIE L*a*b*, o CIE L*u*v* é baseado no CIE XYZ apresentando como um dos canais a luminosidade. O canal u* representa variações entre verde para valores negativos (-u*) e vermelho para valores positivos (+u*) e o canal v* apresenta variações entre azul (-v*) e violeta (+v*).[24, 25]. Uma característica deste espaço de cor assenta no facto de ter sido construído sobre duas escalas de cromaticidade uniformes derivadas de valores *standard* da "teoria dos três estímulos" do XYZ [9]. Apesar deste modelo apresentar a vantagem de a diferença entre duas cores ser proporcional à sua diferença quando visualizadas lado a lado em tons de cinzento, com brilho moderado entre outras, o CIE L*u*v* apresenta uma fraca capacidade na associação de cores sob diferentes cores de iluminação ou diferentes níveis de luminancia [9].

Para a conversão de RGB para CIE L*u*v* recorre-se às Equações 2.24 a 2.28.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$ *Equação 2. 24*

$$L^* = \begin{cases} 116 \times \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16, & if\left(\frac{Y}{Y_n} > \left(\frac{6}{29}\right)^3\right) \\ \left(\frac{29}{3}\right)^3 \times \left(\frac{Y}{Y_n}\right), & if\left(\frac{Y}{Y_n} \le \left(\frac{6}{29}\right)^3\right) \end{cases}$$ *Equação 2. 25*

$$u^* = 13 \times L^* (u' - u'_n)$$ *Equação 2. 26*

$$v^* = 13 \times L^* (v' - v'_n)$$

$$u' = \frac{4 \times X}{X + 15 \times Y + 3 \times Z} = \frac{4 \times x}{-2 \times x + 12 \times y + 3}$$ *Equação 2. 27*

$$v' = \frac{9 \times Y}{X + 15 \times Y + 3 \times Z} = \frac{9 \times y}{-2 \times x + 12 \times y + 3}$$ *Equação 2. 28*

2.2. Lógica Difusa

A análise da cor das folhas de madeira é um processo baseado em conhecimento empírico que depende essencialmente da capacidade do operador. Assim é necessário garantir um sistema que consiga atingir um grau de abstracção e flexibilidade adequado para esta tarefa. Note-se que neste tipo de sistemas uma resposta de apenas verdadeiro ou falso não é suficiente, uma vez que existem inúmeras possibilidades de resultado, como por exemplo, uma folha de madeira pode ser classificada quanto ao seu tipo (árvore de onde provém, quanto a sua tonalidade…) e durante a análise de cor não é viável fazer corresponder a tonalidade de uma folha de madeira a uma cor exacta, pois ou o universo de amostras de cor disponíveis apresentava toda a gama de cores possíveis de serem apresentadas nas folhas de madeira, ou em alguns dos casos não haveria avaliação ou esta seria inconclusiva. Torna-se assim necessário não procurar uma cor ou tonalidade exacta, mas dento do universo de amostras fornecido verificar qual a que mais se aproxima ao sujeito a ser analisado.

A implementação deste sistema recorrendo a lógica difusa é relativamente simples, em que o primeiro passo consiste na criação das classes. Dentro destas classes é necessário definir as funções pertença para cada uma das características. O passo seguinte consiste em determinar o método de inferência ou regras mais adequadas à aplicação em causa. Finalmente é indicada a forma como os valores resultantes da inferência são interpretados. Assim o processo de avaliação pode ser resumido a três etapas: fuzificação (da linguagem Anglo-Saxónica *fuzzification*) em que são recolhidas as características do sujeito a ser analisado e aplicadas a funções de modo a convertê-las para o universo difuso; os valores resultantes da fuzificação serão aplicados ao sistema de inferência de modo a obter um valor único relativamente a cada classe; finalmente surge a fase de desfuzificação (da linguagem Anglo-Saxónica

defuzzification) onde o valor resultante do processo de inferência para cada classe é convertido novamente para o universo não difuso [26].

Recorrendo à lógica difusa é possível implementar o pretendido recorrendo a amostras de folhas de madeira para definir os diferentes resultados possíveis - classes. Na Figura 7 são apresentados exemplos de imagens de amostras de cada um dos tipos de madeira a serem utilizados neste projecto, bem como o histograma de cada canal, para os espaços de cor seleccionados, nomeadamente HSV e CIE L*a*b*, recolhidos dessa amostra.

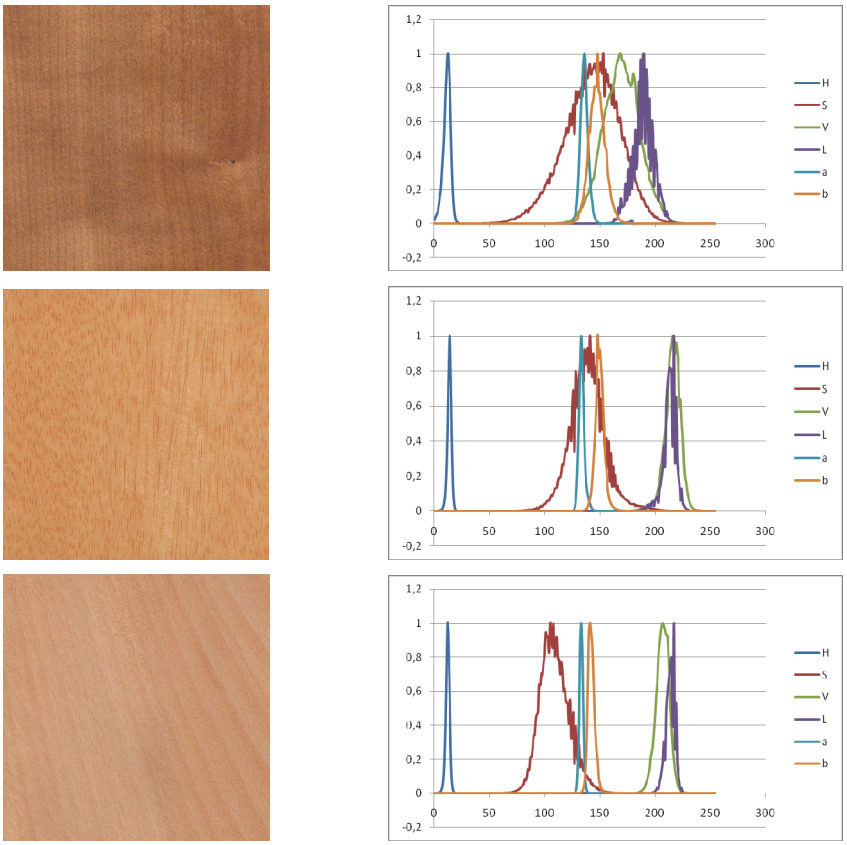

Figura 7 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos diferentes canais que a caracterizam.

Como se pode verificar o conjunto dos histogramas de cada canal apresenta características diferentes para cada uma das amostras, permitindo assim recorrer aos mesmos para identificar uma imagem e distinguir os diferentes tipos de madeira.

Assim de cada amostra serão extraídas características da sua cor, que serão usadas para definir as diferentes classes.

2.2.1 Representação das funções pertença

Numa primeira abordagem foi desenvolvida uma aplicação que convertia a amostra fornecida nos dois espaços de cor seleccionados, procedia à separação nos diferentes canais e recolhia os pontos do histograma para cada canal. Uma vez que nesta fase do projecto as funções pertença eram representadas por triângulos, para a sua implementação, os diversos pontos do histograma eram analisados até encontrar o valor de pico, de seguida percorriam-se os restantes valores a partir desse máximo, tanto para a direita, como para a esquerda até encontrar o primeiro valor nulo para cada um dos lados. (Figura 8)

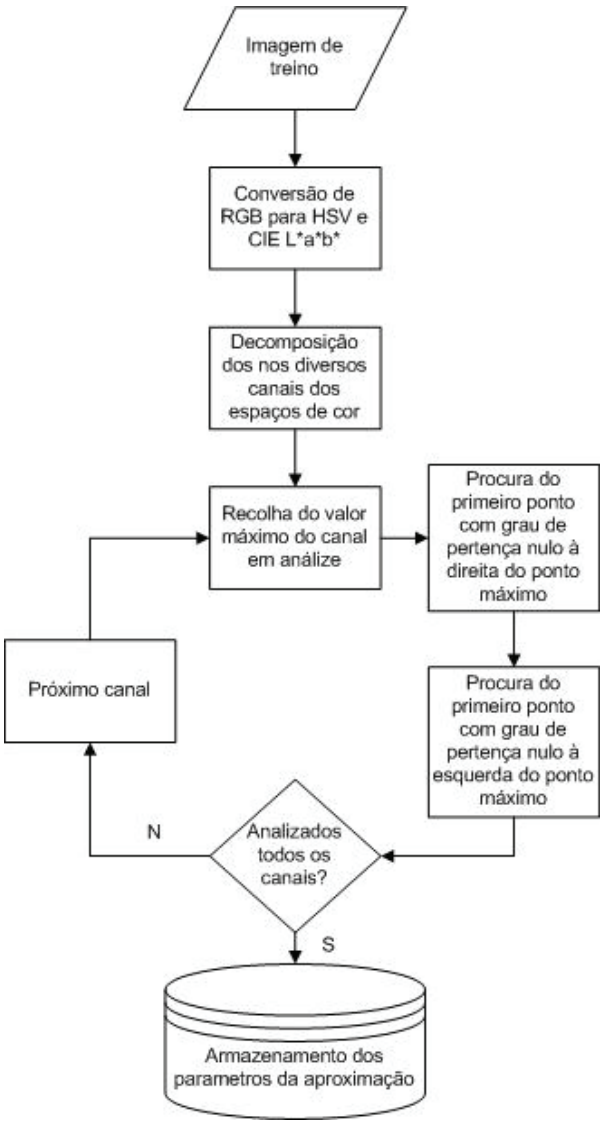
Imagem de treino
Conversão de RGB para HSV e CIE L*a*b*
Decomposição dos nos diversos canais dos espaços de cor
Recolha do valor máximo do canal em análize
Procura do primeiro ponto com grau de pertença nulo à direita do ponto máximo
Procura do primeiro ponto com grau de pertença nulo à esquerda do ponto máximo
Próximo canal
N
Analizados todos os canais?
S
Armazenamento dos parametros da aproximação

Figura 8 – Algoritmo de recolha dos parâmetros dos histogramas para aproximações recorrendo a triângulos.

Com este procedimento estavam então recolhidos os três vértices do triângulo que representaria a função pertença relativamente ao histograma em causa. Este procedimento repetia-se para todas as amostras. Os pontos dos histogramas eram recolhidos recorrendo à aplicação representada na Figura 9 que gerava um relatório em Excel com os pontos dos histogramas de cada canal e os respectivos pontos para a aproximação usando triângulos.

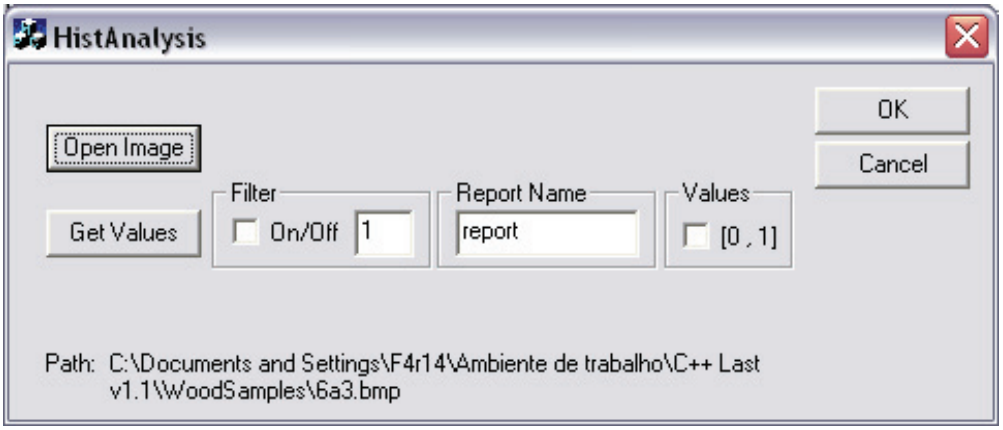

Figura 9 – Aplicação utilizada para recolha dos valores dos histogramas.

Considerando os valores em causa: input (valor máximo do histograma fornecido como entrada), null_left[i] (valor nulo à esquerda do máximo de um histograma de uma amostra), Max[i] (valor máximo de um histograma de uma amostra) e null_right[i] (valor nulo à direita do máximo de um histograma de uma amostra), e tendo em conta que os valores se encontram normalizados e que o máximo é sempre 1 o grau de pertença para uma dada entrada era obtido pela Equação 2.29.

$$\mu(input) = \begin{cases} \frac{1}{Max[i] - null\_left[i]} \times input - \frac{1}{Max[i] - null\_left[i]} \times null\_left[i], & if\ (null\_left[i] \le input \le Max[i]) \\ \frac{1}{null\_right[i] - Max[i]} \times input - \frac{1}{null\_right[i] - Max[i]} \times null\_right[i], & if\ (Max[i] \le input \le null\_right[i]) \end{cases}$$

Equação 2. 29

Recorrendo aos relatórios gerados pela aplicação era possível verificar a precisão das aproximações através do Microsoft Excel. As figuras 10 e 11 representam os resultados obtidos para duas das amostras disponíveis assim com as aproximações associadas ao histograma real de modo a poder observar a eficácia do método em causa.

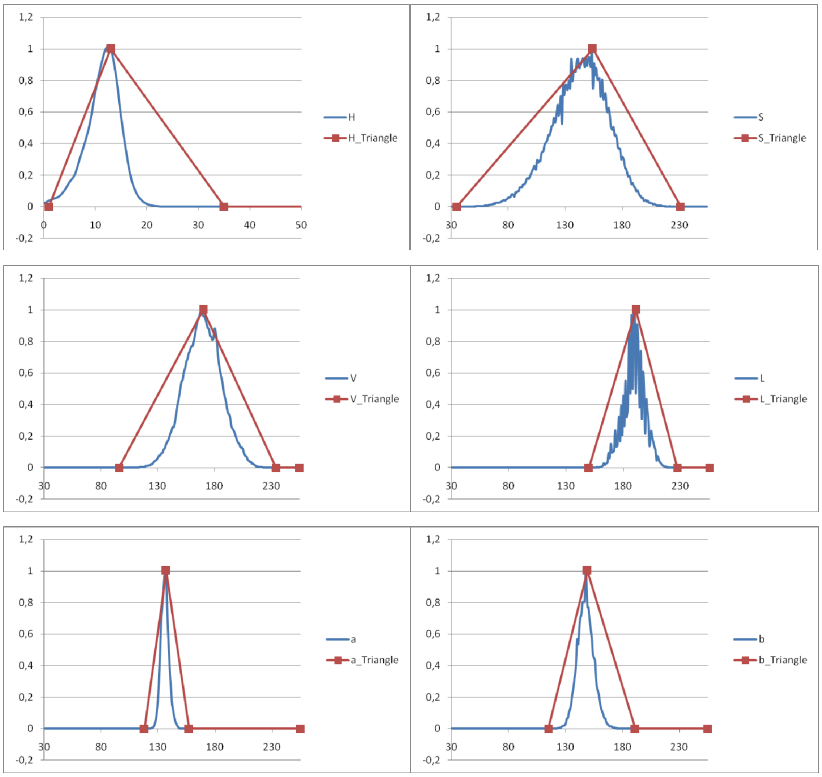

Figura 10 – Aproximações ao histograma real da amostra 1b1 recorrendo a triângulos.

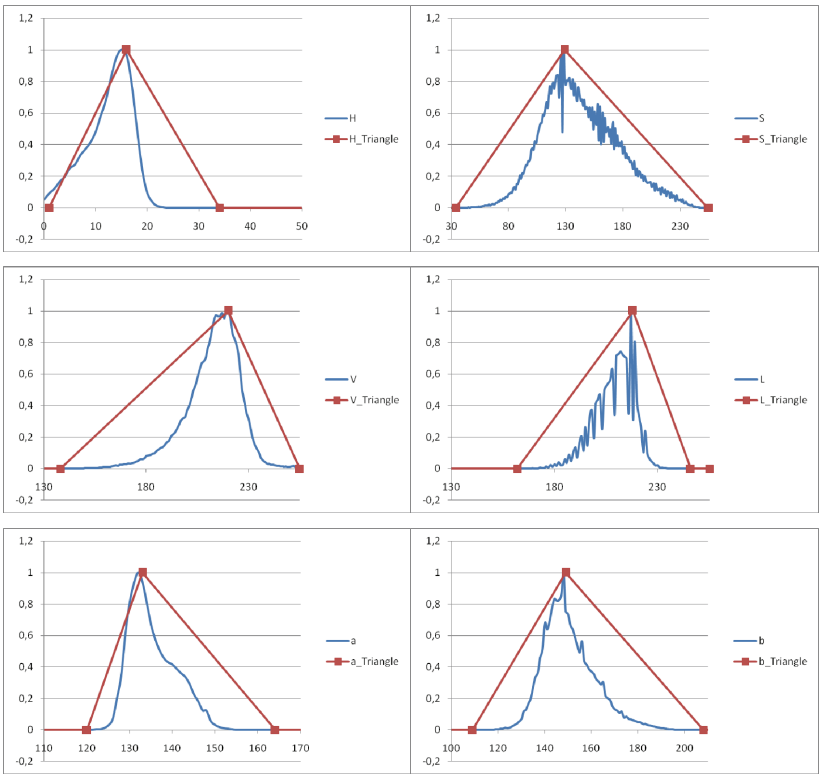

Figura 11 – Aproximações ao histograma real da amostra 6a3 recorrendo a triângulos.

Como se pode verificar as aproximações conseguidas para as amostras 1b1 e 6a3, não são as mais adequadas uma vez que existem uma série de valores practicamente nulos que no entanto são tidos em conta no processo de aproximação o que fazem com que a aréa abrangida por esta representação seja bastante superior à área representada pelo histograma real. Este tipo de situações pode ser problemática em alguns casos uma vez que as tendem a ser representadas caracteristicas, neste caso, cores, que na realidade não existem na amostra de madeira em causa.

Numa fase seguinte a aproximação dos histogramas foi efectuada recorrendo a funções sino [27]. Note-se que a sua forma é bastante semelhante à forma dos histogramas premitindo, que com um bom ajuste dos parametros, seja possivel fazer aproximações bem mais aceitáveis do que as obtidas através dos triângulos. Esse ajuste é feito recorrendo aos três parâmetros apresentados na Equação 2.30, onde o parametro "c" corresponde ao ponto máximo do histograma, "b" ao declive da curva e "a" aos pontos de viragem que afectam directamente a largura do histograma.

$$bell(x,a,b,c) = \frac{1}{1+\left|\frac{x-c}{a}\right|^{2b}}$$

Equação 2. 30

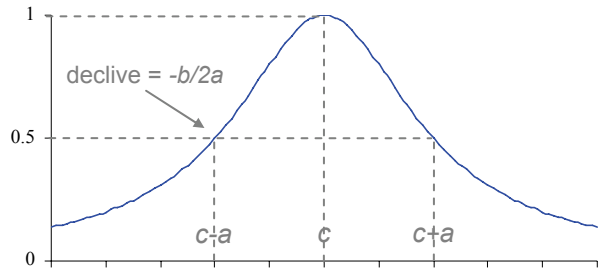

Figura 12 – Representação da função sino e significado dos seus parâmetros.

Para este ajuste foi criada uma folha no Microsoft Excel que ao alterar manualmente os diferentes parametros, os pontos da função eram gerados de maneira a tentar com que esta correspondesse o melhor possivel com o histograma de um dado canal, permitindo assim a comparação do histograma real com a sua aproximação. Note-se que este procedimento é considerado aceitável para verificar a precisão das aproximações, no entanto o seu uso para obtenção das caracteristicas da função representativa da aproximação está fora de questão pois este procedimento encontra-se sujeito ao critério do operador se encontra a parametrizar as aproximações e o tempo necessário é considerado bastante elevado para requisitos industriais.

Nas figura 13 e 14 são apresentadas as aproximações recorrendo a funções sino sobrepostas ao histograma real.

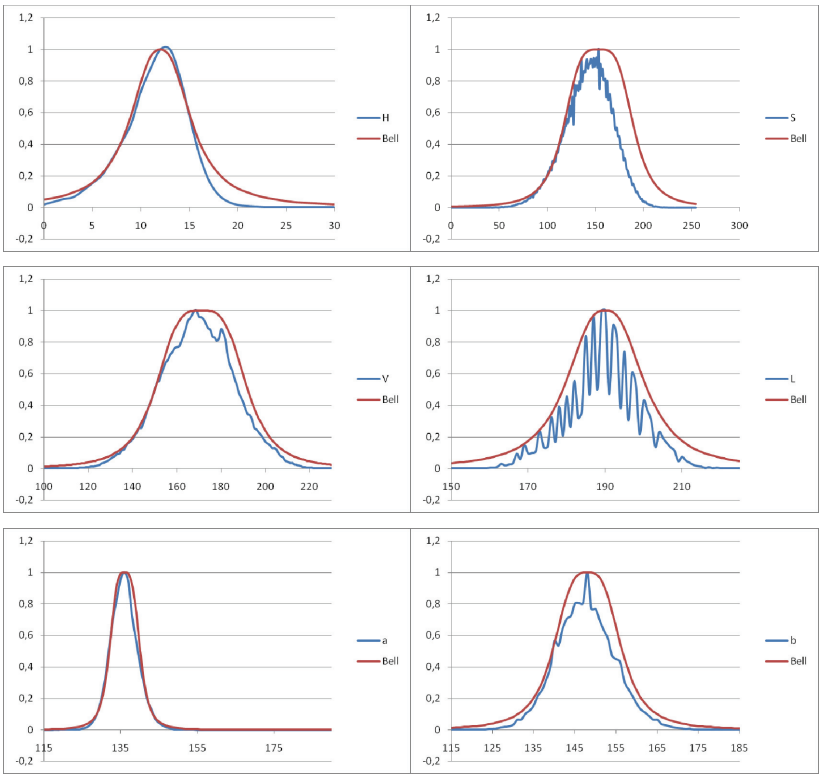

Figura 13 – Aproximações ao histograma real da amostra 1b1 recorrendo a funções sino.

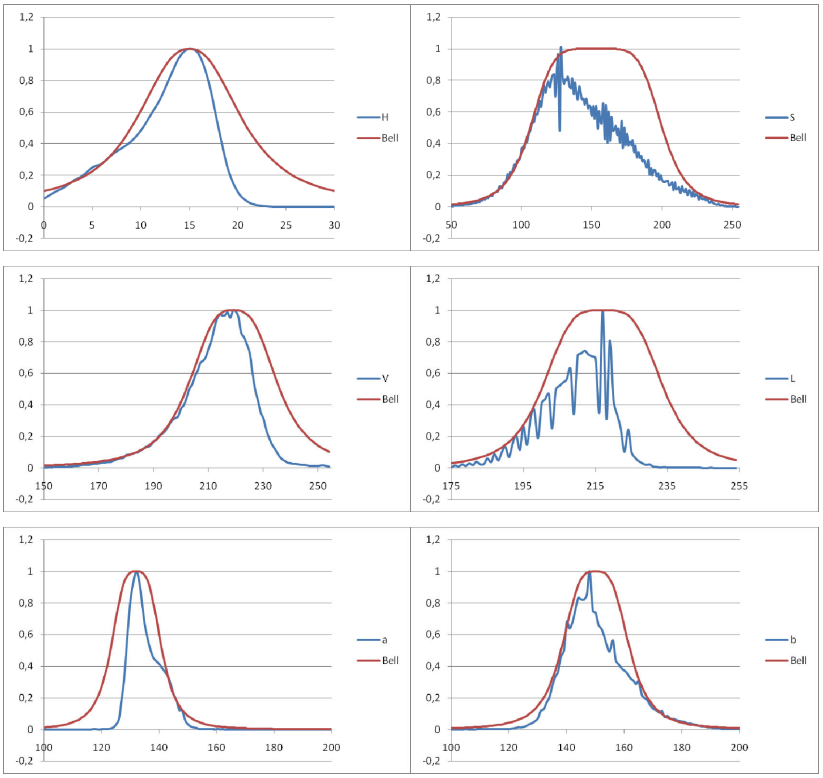

Figura 14 – Aproximações ao histograma real da amostra 6a3 recorrendo a funções sino.

No entanto, como se pode verificar através das imagens algumas das aproximações não se verificaram tão boas quanto esperado, isto porque o histograma não apresenta simetria em relação ao eixo vertical que intercepta o seu valor de pico, o que faz com que, apesar de se conseguir boas aproximações de um dos lados do histograma, nem sempre é possivel garantir bons resultados realtivamente a todo o histograma.

Assim, na tentativa de minimizar este efeito, antes da extracção dos valores as imagens sãp submetidas a um processo de filtragem. Essa filtragem consiste na aplicação de um *smooth* do tipo gaussiano actuando numa vizinhança de 3 pixeis, um número predefinido de dilatações com un kernel 3x3 e para finalizar o mesmo número de erosões, com o mesmo kernel [28]. O objectivo desta filtragem consiste em remover altas frequência, resultando também numa representação mais simétrica do histograma em relação ao eixo vertical que atravessa o ponto máximo do histograma, resultando em aproximações mais precisas. A Figura 15 representa o mesmo exemplo apresentado na Figura 7 mas agora depois de submetidas a um processo de filtragem de uma iteração.

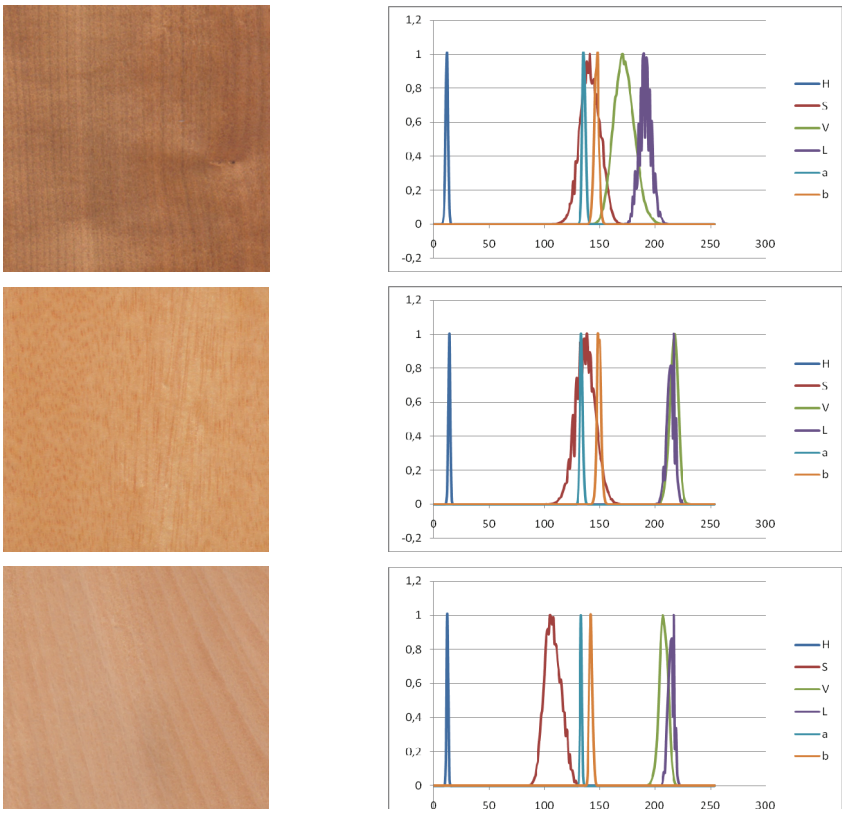

Figura 15 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos canais que a caracterizam depois de submetidos a uma filtragem de uma iteração.

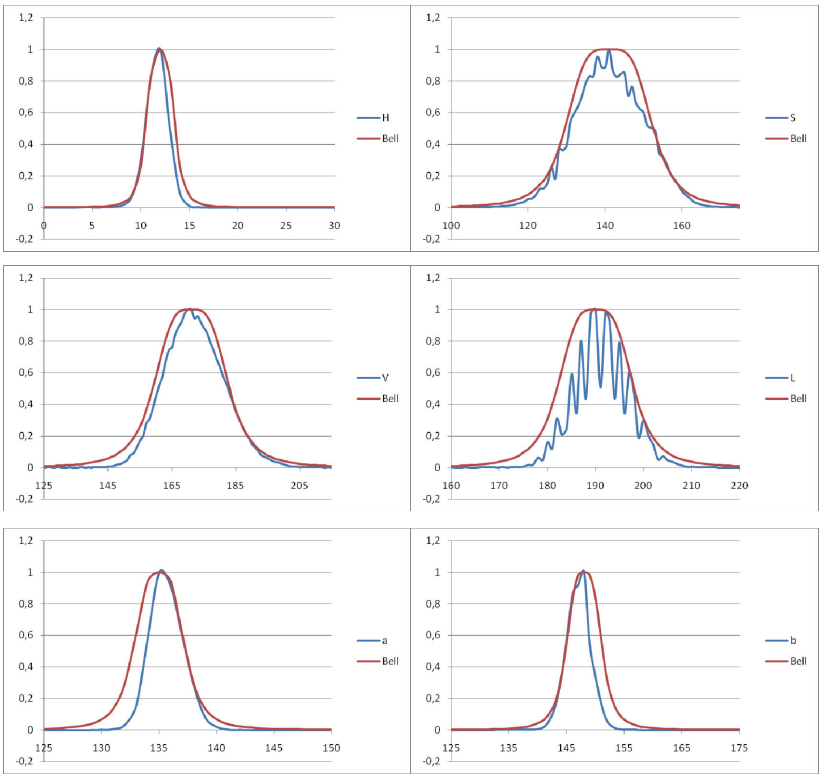

Figura 16 – Aproximações ao histograma real da amostra 1b1 recorrendo a funções sino depois de submetidas a uma filtragem de uma iteração.

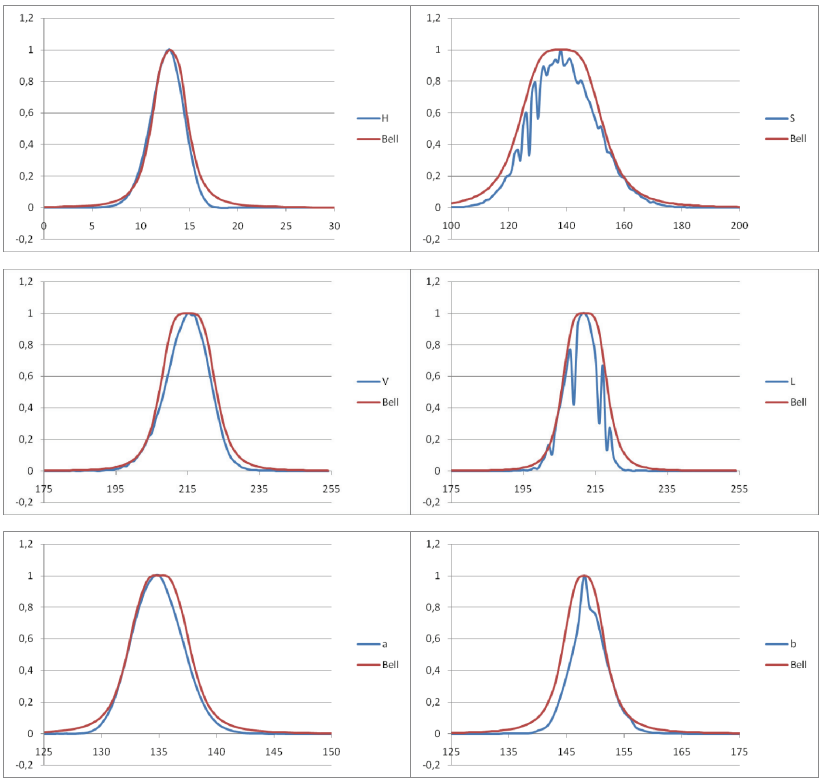

Figura 17 – Aproximações ao histograma real da amostra 6a3 recorrendo a funções sino depois de submetidas a uma filtragem de uma iteração.

Como se pode constatar para a amostra 1b1 as alterações não são muito significativas, uma vez que não se conseguiu obter uma maior simetria em todos os canais. Por outro lado, no que diz respeito à amostra 6a3 já se verificam os efeitos pretendidos com a filtragem uma vez que os pontos recolhidos do histograma apresentavam uma semelhança muito maior às funções sino usadas para fazer as aproximações.

Foram também efectuados testes para cinco, dez e quinze iterações, no entanto para cinco ou mais iterações as caraterísticas da imagem resultante apresentavam-se bastante alteradas, realçando por vezes a textura natural da madeira que se pretendia suavizar e por vezes verificava-se uma acentuação das variações de alta frequencia presentes em alguns dos canais, situações estas que se pretendiam evitar. Os resultados de uma filtragem de cinco iterações são apresentadas na Figura 18.

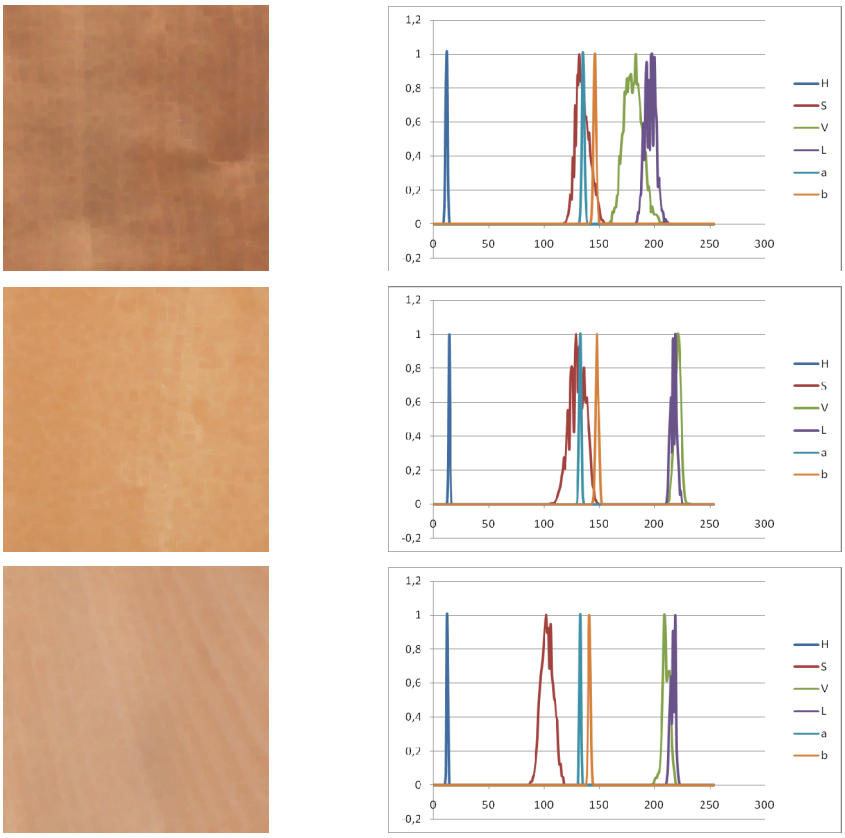

Figura 18 – Amostras dos diferentes tipos de madeira disponíveis e respectivos histogramas dos canais que a caracterizam depois de submetidos a uma filtragem de cinco iterações.

Reparou-se também que na obtenção das imagens recorrendo a um *scanner* por vezes verificavam-se algumas variações de cor que não se encontravam presentes nas folhas de madeira a que se recorreu para a obtenção das amostras. Conseguiu-se

minimizar este problema com o processo de filtragem no entando recorda-se mais uma vez a necessidade de um bom sistema de aquisição da imagem, pois quanto mais preciso for, menor é a probabilidade de erro no processo de avaliação.

2.2.2 Sistemas de inferência

Torna-se necessário optar por um sistema de inferência para interpretar os valores resultantes das funções pertença. Note-se que neste tipo de sistemas pretende-se encontrar a classe mais apta quando fornecida determinada entrada. Tendo em conta que foram usadas aproximações aos histogramas dos canais de diferentes amostras para representar as diferentes classes, e que quanto mais próxima estiver a classe dos valores fornecidos maior vai ser o grau de pertença devolvido pelas funções definidas, optou-se por recorrer a um sistema que devolvesse o valor máximo obtido numa determinada classe. Dos sistemas de inferência referidos anteriormente poderíamos seleccionar entre o Min-Max [27] e o Max-Max no entanto dada a probabilidade de várias classes obterem pelo menos num dos canais grau de pertença muito próximo da unidade descartou-se a possibilidade de recorrer ao Max-Max pois os resultados seriam muito propícios a erros. Recorreu-se então ao Min-Max como sistema de inferência. Mais tarde, no decorrer deste projecto, surgiu a ideia de implementar um novo sistema de inferência a que se chamou Sum-Max.

2.2.3 Min-Max

Após a análise de diferentes métodos de inferência existentes na bibliografia [27, 29] optou-se pelo Min-Max. Tal como se pode verificar na Figura 19 existem duas variáveis, x e y, que são modeladas em duas classes C_1 e C_2 através das funções pertença A_1, B_1 e A_2, B_2, respectivamente. Quando um par de valores (x_i, y_i) é aplicado ao sistema de inferência, a primeira operação é determinar o grau de pertença para cada uma das funções. De seguida, para cada classe (C_1 e C_2) é determinado o valor mínimo, w_2 e w_4, respectivamente. O par irá ser associado à classe que apresentar o valor mínimo mais elevado, neste caso w_2.

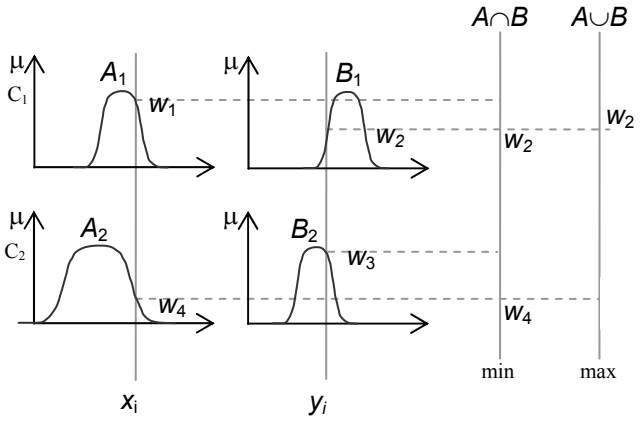

Figura 19 – Representação do funcionamento do método de inferência Min-Max de gramática difusa.

Se analisarmos o seu critério de decisão verificamos que este método de inferência tem em conta o "pior caso" de cada classe para efectuar a avaliação. Ou seja de todos os valores de uma classe será recolhido o valor mínimo, e convém realçar que no caso de uma folha de madeira igual ou semelhante a outra que defina uma classe, esse mínimo deverá apresentar um valor elevado uma vez que as características da imagem deverão ter apenas pequenos desvios da imagem que foi fornecida na fase de treino. Depois de recolher o mínimo de cada classe será verificado qual a classe que apresenta o mínimo mais elevado, sendo essa a classes apresentada como resultado.

2.2.4 Max-Sum

Durante a validação do método Min-Max considerou-se interessante implementar um método, que ao invés de considerar apenas o peso dos dados de um dos canais da imagem obtida, recorre-se ao peso de todos os canais da mesma imagem. Foi então implementado um método a que se chamou Sum-Max (FSMIS). O funcionamento deste método pode se observado na Figura 20. Tal como no exemplo apresentado para o método Min-Max considerem-se duas variáveis, x e y, que são modeladas em duas classes C_1 e C_2 através das funções pertença A_1, B_1 e A_2, B_2, respectivamente. Quando um par de valores (x_i, y_i) é aplicado ao sistema de inferência, a primeira operação é determinar o grau de pertença para cada uma das funções. De seguida, para cada classe (C_1 e C_2) é calculada a soma de todos os graus de pertença, Σ_1 e Σ_2, respectivamente. O par de valores irá ser associado à classe que apresentar o somatório dos graus de pertença mais elevado, neste caso Σ_1.

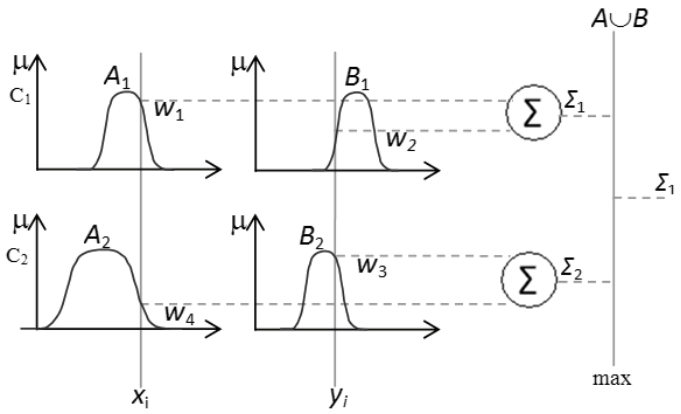

Figura 20 - Representação do funcionamento do método de inferência Sum-Max de gramática difusa.

Para a implementação deste método assumiu-se que ao fazer a correspondência entre duas imagens, a que apresentar maior semelhança irá ter grau de pertença mais elevado para a maioria dos canais, e como consequência, o somatório destes valores irá ser mais elevado relativamente ao apresentado por outras classes.

2.2.5 Gramática Difusa

Este processo [27, 30, 31] consiste em representar um conjunto de funções que abranjam todo o canal do espaço de cor, igualmente espaçadas entre si e com as mesmas características – primitivas. Essas funções serão usadas para representar as aproximações dos histogramas reais de cada canal. Assim sempre que uma imagem é introduzida como objecto de treino vai ser extraído o valor no qual se obtém o máximo de cada canal. Esse valor vai ser aplicado a todas as primitivas e a que apresentar o valor mais elevado será seleccionada para representar esse canal.

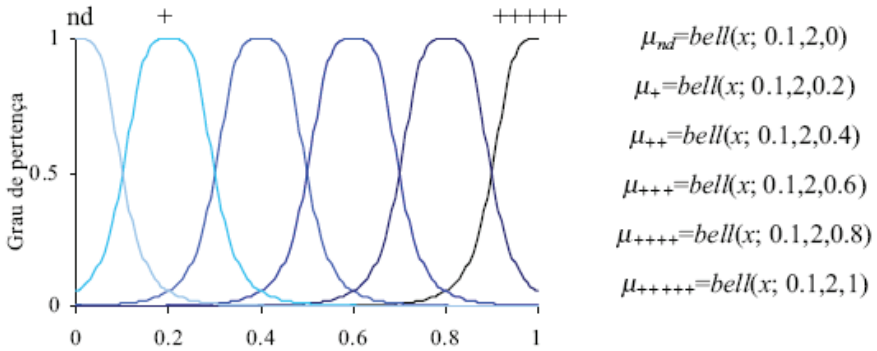

Figura 21 – Exemplo de gramática difusa recorrendo a seis primitivas para descrever todo o universo difuso.

De modo a tornar a representação mais precisa é possível associar mais do que uma primitiva recorrendo aos modificadores linguísticos, para este sistema representados pelos operadores “<”, “>” e “BETWEEN”. Para isso é necessário definir um valor a partir do qual a primitiva passa a desempenhar um papel relevante na aproximação, neste caso foi considerado o valor 0,75. Sempre que mais do que uma primitiva consecutivas se encontrarem no extremo esquerdo do canal é usado o termo “< [primitiva de maior grau]”, caso se encontrem no extremo direito recorre-se ao termo “> [primitiva de menor grau]” e caso estas não se encontrem nos extremos recorre-se ao termo “[primitiva de menor grau] BETWEEN [primitiva de maior grau]”.

O exemplo de uma regra gerada para a classe representativa de uma das amostras, bem como o grau de pertença atribuído às primitivas de cada canal encontram-se representados na Figura 22. Note-se que a regra é constituída pelo número de amostra, neste caso AM1, seguido da equação que representa a classe e o operador @ representando um “e” lógico entre as diferentes funções pertença.

AM1 HistVar:2#Hmax @ HistVar:9 BETWEEN HistVar:10#Smax @ HistVar:10 BETWEEN HistVar:11#Vmax @ HistVar:11 BETWEEN HistVar:12#Lmax @ HistVar:8 BETWEEN HistVar:9#amax @ HistVar:9#bmax

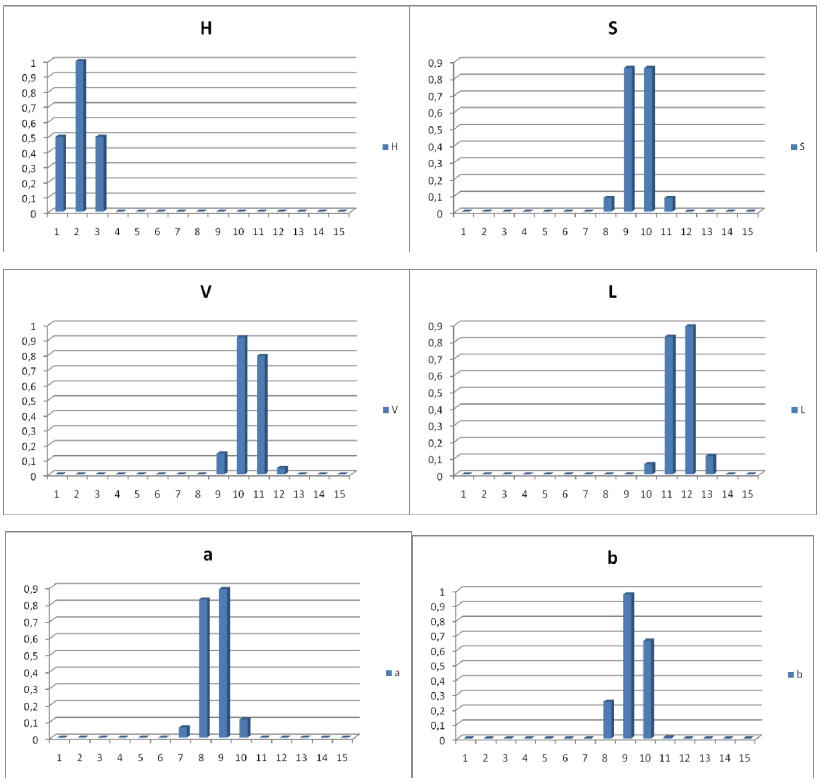

Figura 22 – Representação do grau de pertença de cada primitiva para cada canal em função características extraídas do histograma de uma amostra considerando um universo de 15 primitivas.

É necessário ter especial atenção ao número de funções padrão usadas para a definição de cada canal, uma vez que um número reduzido pode não ser suficiente para a distinção de algumas das amostras. Por outro lado, um número bastante elevado pode não apresentar relevância, caso esse aumento não seja capaz de provocar melhoramentos nas aproximações, e no entanto é traduzido num aumento de processamento.
O algoritmo base implementado para a implementação de gramática difusa pode ser visualizado na Figura 23.

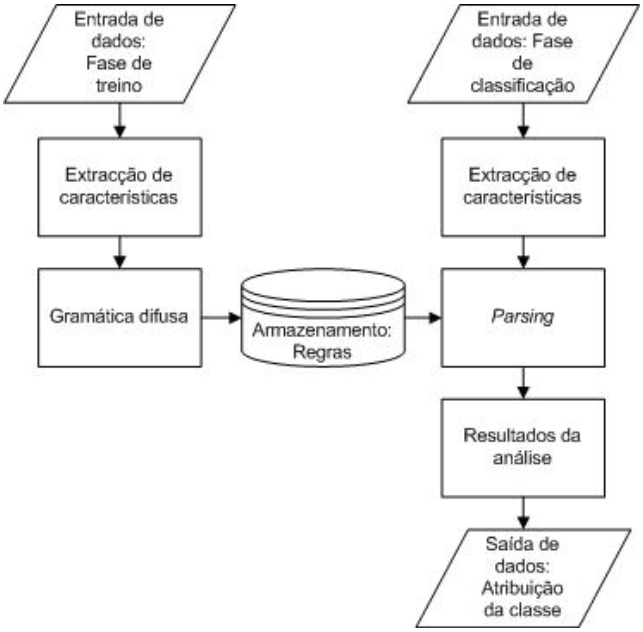

Figura 23 – Algoritmo implementado para o uso de gramática difusa.

Assim, depois da fase de treino, onde são extraídas as características da imagem fornecida, estas são convertidas em regras e armazenadas num ficheiro de texto. Sempre que se pretende efectuar uma avaliação são extraídas as características do histograma de cada canal da imagem em causa – no nosso caso o ponto que apresenta valor mais elevado - e compiladas com as regras. Este conjunto é interpretado pelo *parser* devolvendo o resultado de cada uma das regras depois de aplicados os valores das entradas. Esses valores são analisados e será recolhido o índice da regra que apresentar o valor mais elevado. A regra que devolver o valor mais elevado representa a imagem fornecida como treino que mais se aproxima da imagem que foi sujeita a avaliação.

2.2.6 Parametrização das aproximações.

Nos sistemas de inferência Min-Max e Sum-Max o processo de ajuste e inserção dos parâmetros das amostras é bastante moroso e por vezes susceptível a erros. Isto porque uma vez que estes dados tinham de ser ajustados pelo operador, e assim susceptíveis a diferentes critérios no ajuste, bem como possíveis erros na fase de inserção dos dados no programa. Assim tornou-se necessário arranjar um método de treino automático capaz compensar estes problemas.

No caso dos triângulos o treino seria relativamente simples de automatizar mas depois de concluído que esta não era a melhor abordagem surge a necessidade de procurar um método capaz de fazer uma boa aproximação com funções sino.

Para fazer a aproximação continuou-se a recorrer a funções sino com dois dos parâmetros fixos, mas agora, em vez da sua posição ser fixa, esta fica centrada no valor a partir do qual se obtém o ponto máximo. Note-se que com este tipo de aproximação alguma informação dos histogramas é descartada uma vez que as aproximações tendem a abranger uma menor gama de valores do que o histograma original, no entanto estas conservam as características que são apresentadas em maior abundância.

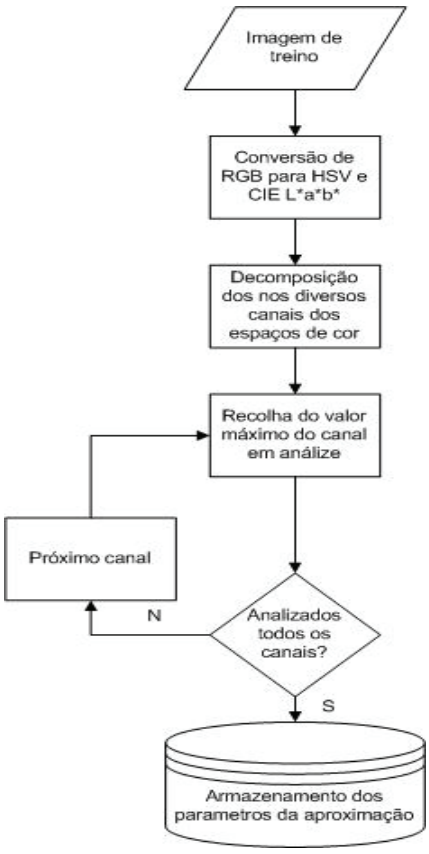
Imagem de treino
Conversão de RGB para HSV e CIE L*a*b*
Decomposição dos nos diversos canais dos espaços de cor
Recolha do valor máximo do canal em análize
Próximo canal
N
Analizados todos os canais?
S
Armazenamento dos parametros da aproximação

Figura 24 – Algoritmo implementado para treino recorrendo a funções sino com dois parâmetros fixos.

Com esta abordagem pretende-se reunir as vantagens dos métodos apresentados anteriormente de modo a conseguir uma representação mais favorável aos resultados pretendidos, uma vez que sendo o ponto máximo do histograma a nossa variável a ser avaliada, faz todo o sentido fazer com que as aproximações estejam de acordo com este critério. Os resultados obtidos através deste método foram bastante favoráveis, no entanto, como se pode verificar na Figura 25, a área abrangida pelos histogramas dos diferentes canais está longe de ser a mesma, levando assim a questionar se o método de aproximação poderia ser melhorado.

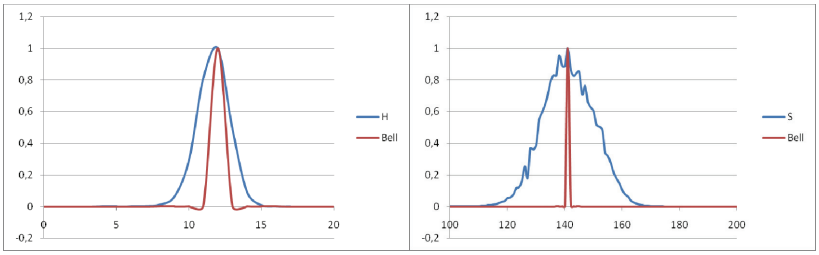

Figura 25 – Comparação entre histograma de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com dois parâmetros fixos.

Para as aproximações passou a ter-se em conta não só o ponto correspondente ao valor máximo do histograma mas também os pontos de viragem. O algoritmo base deste procedimento encontra-se representado na Figura 26.

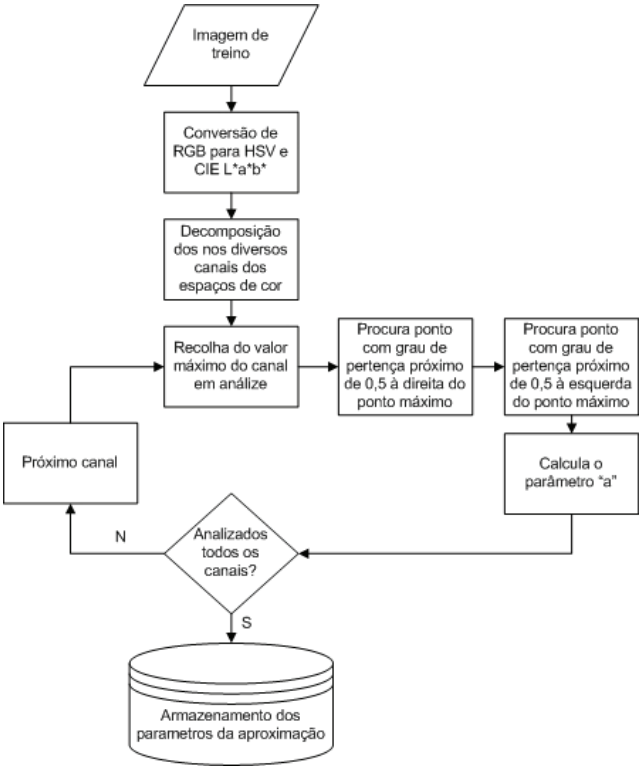
Imagem de treino
Conversão de RGB para HSV e CIE L*a*b*
Decomposição dos nos diversos canais dos espaços de cor
Recolha do valor máximo do canal em análize
Procura ponto com grau de pertença próximo de 0,5 à direita do ponto máximo
Procura ponto com grau de pertença próximo de 0,5 à esquerda do ponto máximo
Calcula o parâmetro "a"
Próximo canal
N
Analizados todos os canais?
S
Armazenamento dos parametros da aproximação

Figura 26 – Algoritmo implementado para treino recorrendo a funções sino com um parâmetro fixo.

Com esta abordagem, apesar de apresentar boas aproximações, verificou-se que em alguns dos casos o processo de correspondência das imagens não era o mais preciso, isto porque havia sobreposição dos histogramas das diversas amostras resultando por vezes valores muito semelhantes que resultavam em falsas correspondências. Estes valores eram resultantes do facto da área abrangida pelos histogramas de alguns canais ser muito elevada fazendo assim que em alguns dos casos a valor mínimo de uma dada amostra fosse bastante elevado, mesmo que o ponto máximo – aspecto fundamental neste processo de avaliação – se encontrasse bastante distanciado.

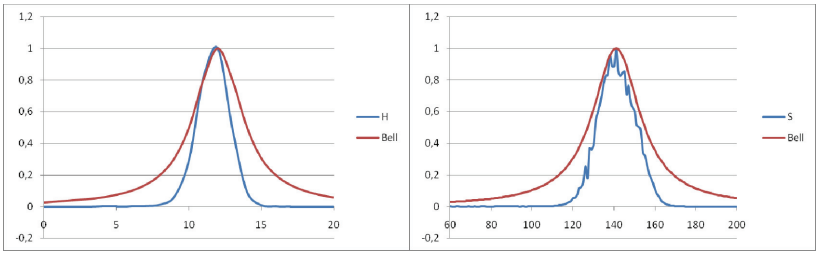

Figura 27 – Comparação entre histogramas de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com um parâmetro fixo.

A solução adoptada para a resolução deste problema por reduzir a área abrangida pelos histogramas através de um factor de divisão. De modo a garantir uma área mínima abrangida pelos histogramas era também adicionada uma unidade ao parâmetro “a”. Sendo (p_{Li} , 0.5) o ponto do histograma associado ao ponto de viragem da função sino do lado esquerdo, (p_{Ri} , 0.5) o ponto do histograma associado ao ponto de viragem da função sino do lado direito e *div* o factor de divisão aplicado o parâmetro *a* era calculado através da Equação 2.31.

$$a = \frac{(p_{RI} - p_{Li})}{div} + 1 \qquad \textit{Equação 2. 31}$$

Para efeitos de aproximação o parâmetro *b* foi mantido constante com o valor 1 e como já foi referido anteriormente o parâmetro c corresponde ao ponto do histograma normalizado (p_i , 1).

Deste modo conseguiu garantir-se a relação entre áreas dos diferentes histogramas, bem como evitar que estas interferissem de forma negativa no processo de avaliação.

Depois de analisadas as duas abordagens torna-se importante referir que apesar de quando se recorre apenas a um parâmetro fixo estamos a proceder a uma aproximação mais rigorosa, a probabilidade de fazer com que umas representações

interfiram com o espaço ocupado com outras classes é maior ao adicionar novas amostras, tendo em conta que quando se recorria a dois parâmetros fixos uma das preocupações era minimizar a área da aproximação ao histograma. No entanto esta situação pode ser controlada manipulando os factores de divisão e adição sempre que se verifique alguma irregularidade nos resultados.

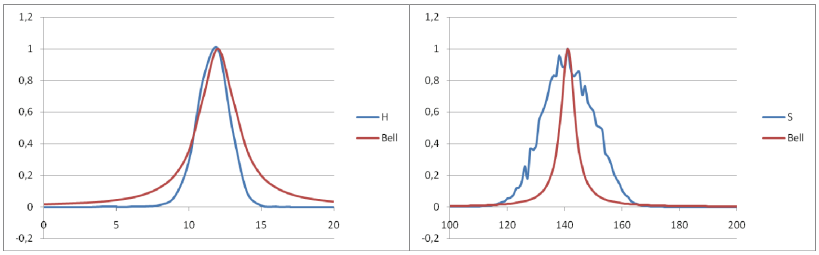

Figura 28 – Comparação entre histogramas de cor de um dos canais de uma imagem e a sua aproximação recorrendo a funções sino com um parâmetro fixo.

2.2.7 Outras considerações

De maneira a classificar as diferentes zonas de uma folha de madeira recorreu-se a um varrimento através de janelas. Este método consiste na divisão da imagem recolhida em porções de tamanho inferior que serão também submetidas a avaliação de modo a poder verificar possíveis variações apresentadas nas folhas de madeira.

Sempre que uma imagem é submetida a avaliação é-lhe feita uma análise global, ou seja, a imagem é avaliada na sua totalidade e fica assim associada a um tipo de madeira, a uma tonalidade e a um número de amostra. Depois vai ser executado um varrimento de toda a imagem através de uma janela de menor dimensão. Os resultados de cada análise parcial são armazenados de modo a calcular as estatísticas da avaliação tendo em conta se, em cada análise parcial, há uma total correspondência com a análise global, apenas com o tipo de madeira e tonalidade (desprezando assim o número de amostra), apenas com o tipo de madeira, ou se corresponde a um tipo de madeira que não o obtido na análise global. Depois de percorrida toda a imagem procede-se ao cálculo da estatística que será armazenado num ficheiro para uma consulta posterior. O algoritmo base encontra-se representado na Figura 29.

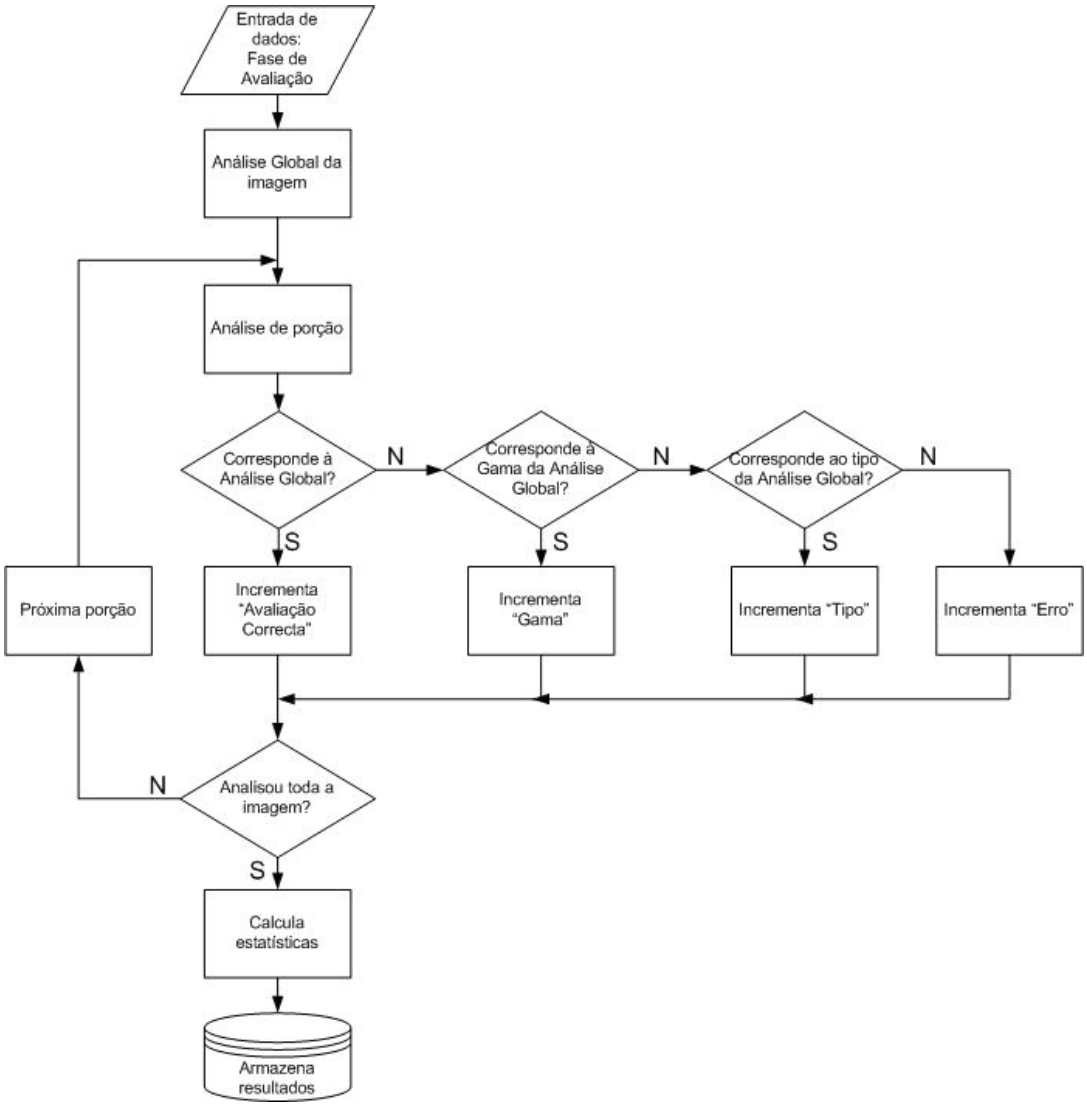

Figura 29 – Algoritmo implementado para o processo de avaliação das amostras.

Para executar os testes há diversos factores a ter em conta de modo a tornar a avaliação mais adequada ao processo onde se pretende inserir este sistema.

Um desses factores consiste no tamanho da porção de imagem a ser avaliada, e consequentemente o modo de como esta porção é obtida. Uma vez que se está a aplicar um filtro torna-se necessário escolher o número de iterações para o mesmo de modo a diminuir o ruído de alta frequência sem deteriorar as características da imagem.

Deste modo foram recolhidos resultados para porções de imagem com 50, 100, 200 e 400 pixéis (D). Para o varrimento da imagem – Análise Parcial - recorreu-se a quatro métodos distintos: Redimensionamento da imagem original para múltiplos da dimensão da porção; Porções de tamanhos diferentes, em que a maioria das porções apresentava o tamanho pretendido mas na última "coluna" o tamanho correspondia

apenas à parte da imagem que ainda não tinha sido avaliada, diminuindo assim a largura da porção, sucedendo o mesmo na última “linha” mas neste caso afectando a altura da porção; Full-Step todas a porções apresentam o tamanho predefinido e a situação indicada anteriormente era corrigida posicionando as ultimas porções em relação aos extremos da imagem, provocando assim a sobreposição de algumas delas; e por fim Half-Step, em que o processo é semelhante ao Full-Step mas neste caso os avanços da porção a ser avaliada são feitos em relação à posição anterior de acordo com os parâmetros *dx* e *dy*, considerando estes valores sempre inferiores ao tamanho da janela (D), neste caso D/2 garantindo assim que existe sobreposição de janelas em todas as análises. Os deslocamentos do método Half-Step encontram-se representados na Figura 30.

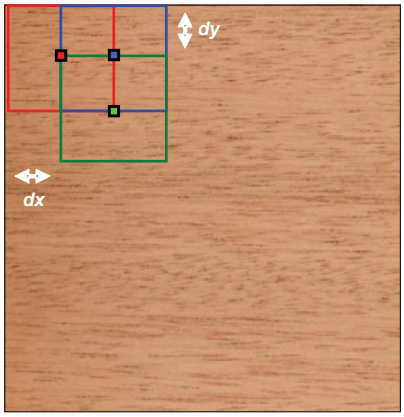

Figura 30 – Representação dos deslocamentos da janela relativamente à posição anterior durante o processo de varrimento da imagem.

A forma de como o escalonamento das imagens é efectuado, pode ser visualizado na Figura 31, que apresenta a imagem original dividida em janelas com D=100 para os quatro métodos referidos. Uma vez que, em alguns dos casos, no extremo direito e no extremo inferior da imagem o deslocamento da janela é efectuado de modo diferente, recorreu-se a cores diferentes na sua representação de modo a facilitar a percepção. Isto porque em vez de considerar um deslocamento em relação à posição anterior da janela é tido em conta o extremo da imagem, recuando-se o tamanho da janela em relação a este.

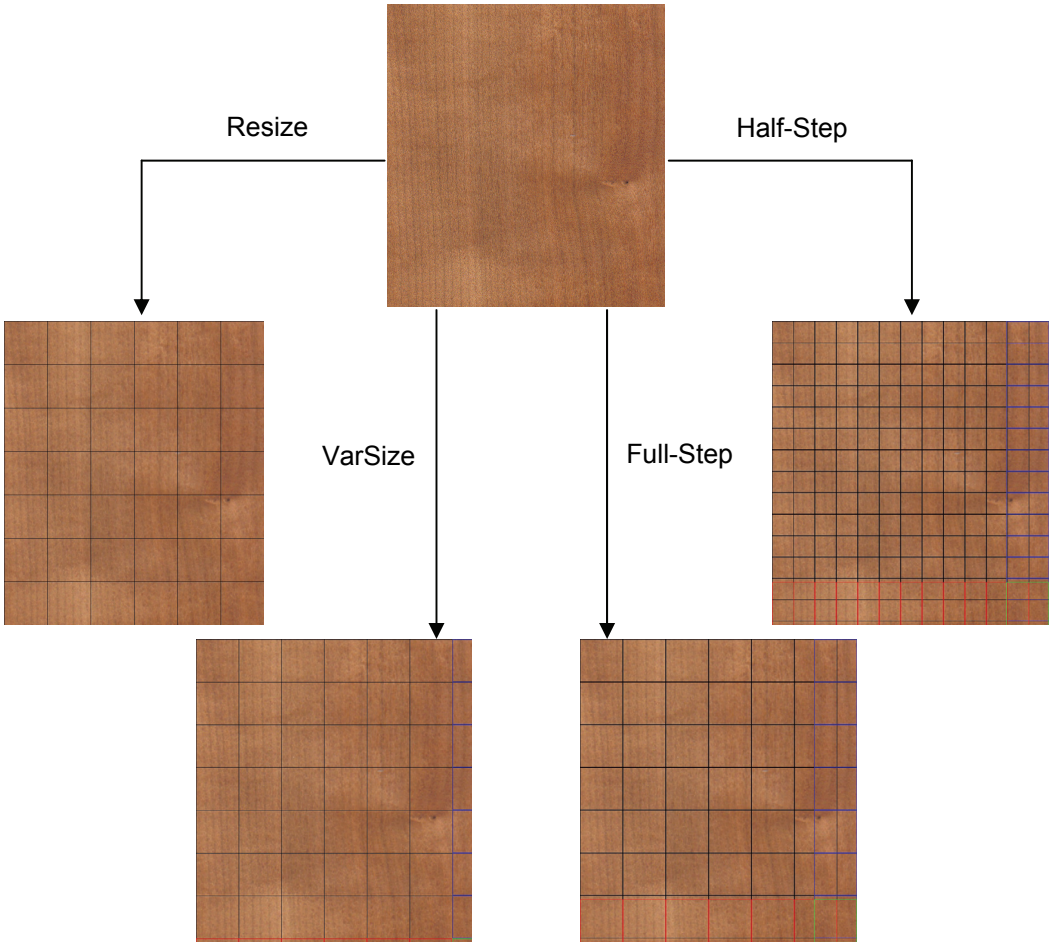

Figura 31 – Representações das porções submetidas a avaliação durante o varrimento da imagem.

Para a validação do método mais apropriado foram executados testes para diferentes combinações de abordagens.

Outro factor a ter em conta é o universo de amostras, uma vez que o número de amostras disponíveis para diferentes tipos e tonalidades de madeira tem grande impacto nos resultados. É necessário assim garantir que as amostras são cuidadosamente seleccionadas de modo a garantir uma boa cobertura das diferentes tonalidades que se pretende classificar, para os diferentes tipos de madeira. Note-se que a falta de amostras será traduzida numa menor sensibilidade relativamente às variações de tonalidade podendo mesmo resultar em falsas correspondências entre diferentes tipos de madeira; por outro lado, um número excessivo de amostras poderá resultar em classes muito próximas, ao ponto de não serem diferenciadas, sendo apenas este aumento do número de classes traduzido num aumento de processamento.

Para efeito de teste em laboratório foram disponibilizadas 23 amostras: tipo a = {2a2, 2a3,3a2, 3a3, 4a1, 4a2, 4a3, 5a1,5a2, 6a1,6a2,6a3}; tipo b = {1b1, 1b2, 1b3}; tipo c = {1c2, 1c3, 2c1, 2c2, 2c3, 3c1, 3c2, 3c3}.

3. Apresentação e discussão dos resultados

Foi necessário proceder a uma análise dos resultados produzidos por cada um dos métodos referidos no ponto anterior. Esses resultados consistem em relatórios de estatísticas e nas imagens segmentadas resultantes da avaliação de cada uma das amostras. Note-se que os relatórios e as imagens segmentadas, encontram-se directamente ligadas uma vez que os dados presentes nos relatórios são a representação estatística das imagens, bem como parâmetros de identificação das amostras para ajudar à sua compreensão.

3.1. Métodos de Teste e Análise de Resultados

O aspecto da aplicação final é apresentado na figura 32. Nesta fase o processo de avaliação, quando se pretende fazer um varrimento (da linguagem Anglo-Saxónica *sweep*) (3), pode ser resumido a três passos simples.

Numa primeira fase é feita uma avaliação da imagem total de modo a determinar o tipo de madeira e a sua tonalidade. O resultado desta avaliação é apresentado na *static text* (3) no lado direito da janela onde se pode visualizar 5a1. De seguida é efectuada a mesma avaliação mas para as pequenas porções da imagem e esses resultados são apresentados tendo em conta o resultado da avaliação geral. Ou seja, sendo 5a1 uma amostra do tipo “a”, tonalidade 5 e número de amostra 2, o resultado da avaliação parcial será *Correct Evaluation* sempre que seja devolvido 5a1, *Correct Gamma* se o numero de amostra não for o mesmo (neste caso sempre que no resultado esteja presente 5a..), *Correct Type* se o resultado apenas coincidir com o tipo de madeira (para o exemplo dado, tipo a) e *Bad Evaluation* se o tipo de madeira não for o mesmo. Finalmente é efectuada uma estatística que é apresentada na *listbox* (8) do lado direito da janela, bem como as imagens resultantes da avaliação (11) e (12), na parte inferior da mesma. É também gerado um relatório em formato de texto para consulta posterior.

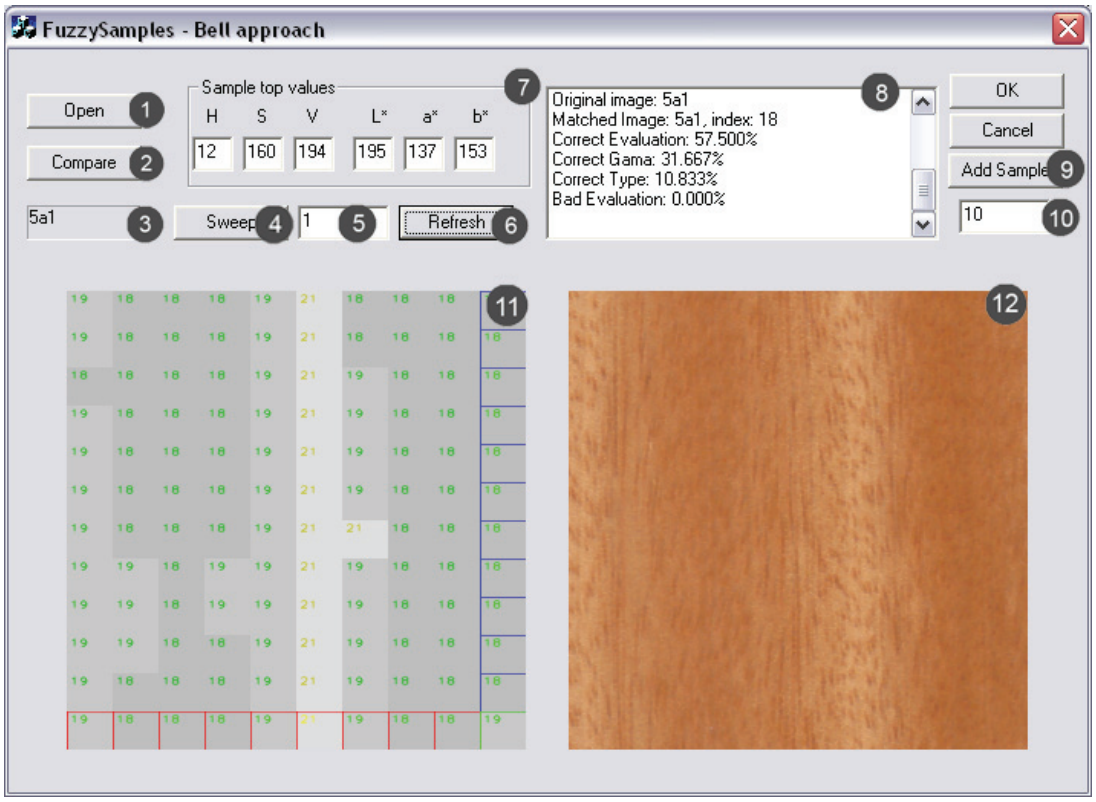

Figura 32 – Aspecto da aplicação desenvolvida para teste dos diferentes métodos.

Através desta aplicação pode também fazer-se apenas a análise global recorrendo ao botão *Compare* (2). Sempre que é executada uma análise global, os parâmetros da imagem a ser analisada são apresentados em (7). A *editbox* identificada como (5) indica o número de iterações a serem usadas durante a filtragem. Note-se que este valor tem de ser considerado não só ao efectuar uma análise mas também durante a fase de treino do sistema. Sempre que se efectua treino (9), deve ter-se em conta o valor associado a (10) que representa o factor de divisão quando se usa o parâmetro da função “a” dinâmico.

Como primeiro passo foi testada a capacidade do sistema fazer a correspondência das imagens na sua totalidade, sendo este o requisito mais simples pretendido com a aplicação e que serve de base ao resto do processo de avaliação. Neste ponto apenas foram considerados testes recorrendo a gramática difusa e sistemas de inferência Min-Max e Sum-Max. Para as aproximações recorrendo a funções sino consideraram-se as abordagens em que se mantinham dois dos parâmetros fixos (“a” e “b”) e apenas um dos parâmetros fixos (“b”). No caso de apenas um dos parâmetros fixos foi necessário verificar o efeito do factor de divisão aplicado nos resultados de modo a melhorar a estratégia.

O passo seguinte foi avaliar os resultados produzidos por cada um dos testes, mas neste ponto, já recorrendo também à avaliação de pequenas porções de cada imagem. Para isso foram considerados as abordagens referidas anteriormente denominadas de Resize, VarSize, Full-Step e Half-Step. Para cada um dos métodos foi tido em conta o efeito do tamanho de cada janela, o deslocamento dessa mesma janela em relação à posição anterior e o efeito do factor de divisão aplicado nas aproximações sino de apenas um parâmetro fixo.

3.1.1 Lógica Difusa aplicada na análise global da imagem

Na tentativa de validar o método que recorria a gramática difusa foram executados testes com nove amostras disponíveis, de modo a determinar o número de primitivas mais adequado para preencher todo o canal. Desses testes convém mencionar os resultados para onze, quinze e dezassete primitivas.

Os resultados obtidos a recorrendo a gramática difusa foram considerados satisfatórios, no que diz respeito a uma avaliação global da imagem – entenda-se que com avaliação global da imagem considera-se a correspondência entre imagens fornecidas como treino e posteriormente submetidas a análise como sujeito de teste - quando o universo de amostras era bastante reduzido. Ou seja, para o conjunto de nove amostras apenas um par de amostras apresentava regras semelhantes, quer recorrendo a um conjunto de quinze, quer a um conjunto de dezassete primitivas para preencher todo o canal. Caso o número de primitivas fosse reduzido para onze já dois pares amostras apresentavam regras semelhantes. Deste modo o número de termos linguísticos seleccionado foi quinze e a sua definição pode ser visualizada na Tabela I.

TABELA I

Designação e função dos termos linguísticos implementados para efeito de teste do método recorrendo a gramática difusa.

Designação	Função
HistVar:0	$\mu(x) = \Pi(x, 0.1429, 0.0000)$
HistVar:1	$\mu(x) = \Pi(x, 0.1429, 0.0714)$
HistVar:2	$\mu(x) = \Pi(x, 0.1429, 0.1429)$
HistVar:3	$\mu(x) = \Pi(x, 0.1429, 0.2143)$
HistVar:4	$\mu(x) = \Pi(x, 0.1429, 0.2857)$
HistVar:5	$\mu(x) = \Pi(x, 0.1429, 0.3571)$
HistVar:6	$\mu(x) = \Pi(x, 0.1429, 0.4286)$

HistVar:7	μ(x) = Π(x, 0.1429, 0.500)
HistVar:8	μ(x) = Π(x, 0.1429, 0.5714)
HistVar:9	μ(x) = Π(x, 0.1429, 0.6429)
HistVar:10	μ(x) = Π(x, 0.1429, 0.7142)
HistVar:11	μ(x) = Π(x, 0.1429, 0.7857)
HistVar:12	μ(x) = Π(x, 0.1429, 0.8571)
HistVar:13	μ(x) = Π(x, 0.1429, 0.9286)
HistVar:14	μ(x) = Π(x, 0.1429, 1)

Caso o número de amostras fosse aumentado para o conjunto de vinte e três amostras referido anteriormente, o número de amostras susceptíveis a serem confundidas aumentava para onze.

Analisando o método usado para as aproximações do histograma real recorrendo a gramática difusa e recorrendo aos sistemas de inferência Min-Max e Sum-Max com as funções pertença centradas no ponto que apresenta valor máximo em cada canal da imagem fornecida como treino, não é difícil de constatar que as aproximações baseadas em gramática difusa são mais susceptíveis a erro.

3.1.2 Lógica Difusa aplicada na análise de porções da imagem.

Foi decidido que o redimensionamento da imagem original deveria ser evitado uma vez que este implicaria recorrer-se a métodos de interpolação podendo assim afectar a relação entre determinados defeitos e a área abrangida por eles; o uso de janelas de diferentes tamanhos não faz grande sentido pois, o tamanho das janelas afecta directamente a avaliação, fazendo com que o critério de avaliação variasse para diferentes porções da mesma amostra, excluindo-se assim o método denominado de VarSize.

O critério de avaliação presente nos métodos denominados de Full-Step e Half-Step é o mesmo, sendo a única variação a distância de deslocamento da janela em relação à posição anterior. Assim, e relembrando que o Half-Step apresenta um deslocamento correspondente a metade da dimensão da janela (D/2), verifica-se uma sobreposição de porções a ser avaliadas. Isto traduz-se num aumento de porções a serem avaliadas e consequentemente, num aumento do rigor da avaliação.

Por estes motivos considerou-se que o método a ser desenvolvido a partir deste ponto seria o Half-Step. Até ao momento, para os testes realizados, recorreu-se a

aproximações ao histograma real através de funções sino com dois dos parâmetros fixos. De modo a aperfeiçoar o Half-Step, este será implementado com apenas um parâmetro fixo nas funções sino usadas nas aproximações ao histograma real e recorrendo ao sistema de inferência Min-Max.

TABELA II

Percentagem de erro nos diferentes métodos abordados com D=100

	Resize	VarSize	FullStep	HalfStep	Auto /8	Auto/ 10
1b1	0	1,786	0	0,595	0,595	4,762
1b2	14,286	16,071	16,071	17,778	17,222	21,667
1b3	8,163	0	1,786	2,747	0	12,088
1c2	2,381	2,083	2,083	0,649	0	0
1c3	0	0	0	0	0	0
2a2	0	0	0	0	0	0
2a3	0	0	0	0	0	0
2c1	22,857	30,000	27,500	22,963	7,407	0,741
2c2	22,222	16,667	16,667	20,000	6,154	26,154
2c3	0	2,222	2,222	0,694	0	0
3a2	0	0	0	0	0	0
3a3	0	0	0	0	0	0
3c1	0	0	0	0	0	0
3c2	0	0	0	0	0	0
3c3	0	0	0	0	0	3,306
4a1	2,381	12,245	8,163	3,846	4,487	0
4a2	0	3,571	0	0	0,556	0
4a3	20,408	21,429	23,214	21,429	26,190	12,500
5a1	0	0	0	0	0	0
5a2	44,898	0	0	0	0	0
6a1	0	2,500	5,000	3,704	5,185	0,741
6a2	0	0	0	0	0	0
6a3	0	0	0	0	0	0

Como se pode verificar, de acordo com os resultados apresentados nas TABELA II a percentagem de erro para janelas de 100 pixéis estão em algumas das amostras apresentando taxas de erro bastante superiores ao pretendido. Note-se também que para algumas das amostras a variação da taxa de erro não é considerada relevante no que diz respeito à alteração do método. No entanto os valores apresentados a vermelho correspondem ao resultado de uma avaliação global que não coincidiu com a imagem introduzida com a imagem fornecida como entrada. Assim só foi conseguida

uma avaliação global de 100%, tendo em conta o universo de amostras, para o método denominado de Auto/10. Auto/10 corresponde a uma análise em Half-Step, método de inferência Min-Max, recorrendo a aproximações baseadas em funções sino com apenas um parâmetro fixo e factor de divisão de 10 unidades.

TABELA III

Percentagem de erro nos diferentes métodos abordados com D=200

	Resize	VarSize	FullStep	HalfStep	Auto /8	Auto/10
1b1	0	0	0	0	0	0
1b2	8,333	12,500	12,500	14,286	14,286	19,048
1b3	0	0	0	0	0	14,286
1c2	0	0	0	0	0	0
1c3	0	0	0	0	0	0
2a2	0	0	0	0	0	0
2a3	0	0	0	0	0	0
2c1	44,444	25,000	16,667	17,857	7,143	0
2c2	55,556	25,000	41,667	36,667	6,667	26,667
2c3	0	6,667	6,667	3,125	0	0
3a2	0	0	0	0	0	0
3a3	0	0	0	0	0	0
3c1	0	0	0	0	0	0
3c2	0	0	0	0	0	0
3c3	0	0	0	0	0	0
4a1	0	0	0	0	0	0
4a2	0	0	0	0	0	0
4a3	8,333	18,750	18,750	14,283	21,429	9,524
5a1	0	0	0	0	0	0
5a2	0	0	0	0	0	0
6a1	0	0	0	0	0	0
6a2	0	0	0	0	0	0
6a3	0	0	0	0	0	0

Comparando agora os resultados com os obtidos para uma janela de 100 pixéis verificou-se uma descida significativa na taxa de erro no entanto em alguns dos casos a taxa de erro é bastante superior ao pretendido, como por exemplo a amostra 2c2 em que a porção indicada como erro na imagem segmentada (Figura 33) corresponde à imagem 4a3.

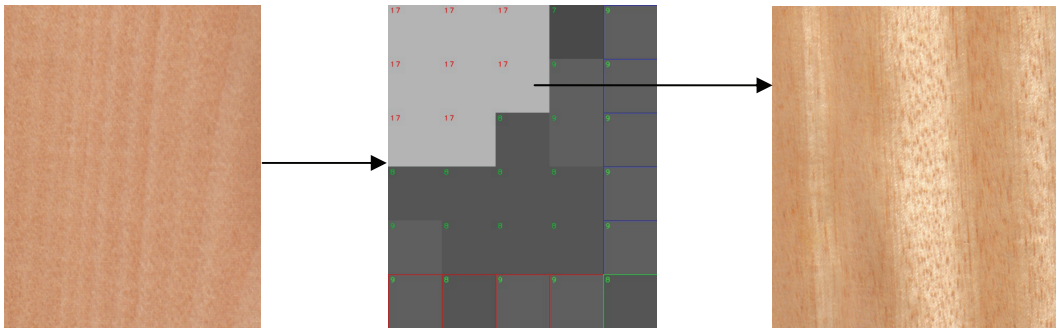

Figura 33 – Amostra 2c2 (a), respectiva segmentação (b) e amostra 4a3 (c).

TABELA IV

Percentagem de erro nos diferentes métodos abordados com D=400

	Resize	VarSize	FullStep	HalfStep	Auto /8	Auto/10
1b1	0	0	0	0	0	0
1b2	0	0	0	0	0	0
1b3	0	0	0	0	0	14,286
1c2	0	0	0	0	0	0
1c3	0	0	0	0	0	0
2a2	0	0	0	0	0	0
2a3	0	0	0	0	0	0
2c1	0	25,000	0	0	0	0
2c2	0	25,000	25,000	16,667	0	33,333
2c3	0	0	0	0	0	0
3a2	0	0	0	0	0	0
3a3	0	0	0	0	0	0
3c1	0	0	0	0	0	0
3c2	0	0	0	0	0	0
3c3	0	0	0	0	0	0
4a1	0	0	0	0	0	0
4a2	0	0	0	0	0	0
4a3	0	25,000	50,000	22,222	22,222	22,222
5a1	0	0	0	0	0	0
5a2	0	0	0	0	0	0
6a1	0	0	0	0	0	0
6a2	0	0	0	0	0	0
6a3	0	0	0	0	0	0

Verifica-se mais uma vez que o aumento da janela conseguiu eliminar o erro para algumas das amostras no entanto este permaneceu presente em três das amostras

para o método Auto/10. Isto porque amostras de outro tipo de madeira apresentavam características de cor mais semelhantes à porção a que foi atribuído o resultado errado.

Pela análise das tabelas I, II e III pode verificar-se que algumas das amostras apresentaram independentemente do método e dimensão da janela usada apresentaram taxa de erro nulo. Note-se que para todas as abordagens estudadas, excepto para o *Half-Step* com apenas um dos parâmetros fixos nas aproximações a funções sino, encontram-se representados a vermelho para a amostra 1b1. Isto significa que ao fazer a correspondência da imagem na totalidade o sistema não devolveu a imagem original, ou seja, sempre que a imagem da amostra 1b1 era submetida a análise, o resultado da análise global devolvido era 1b3. Assim optou-se por um factor de divisão de dez unidades pois este fez com que fosse possível efectuar a distinção de todas as amostras.

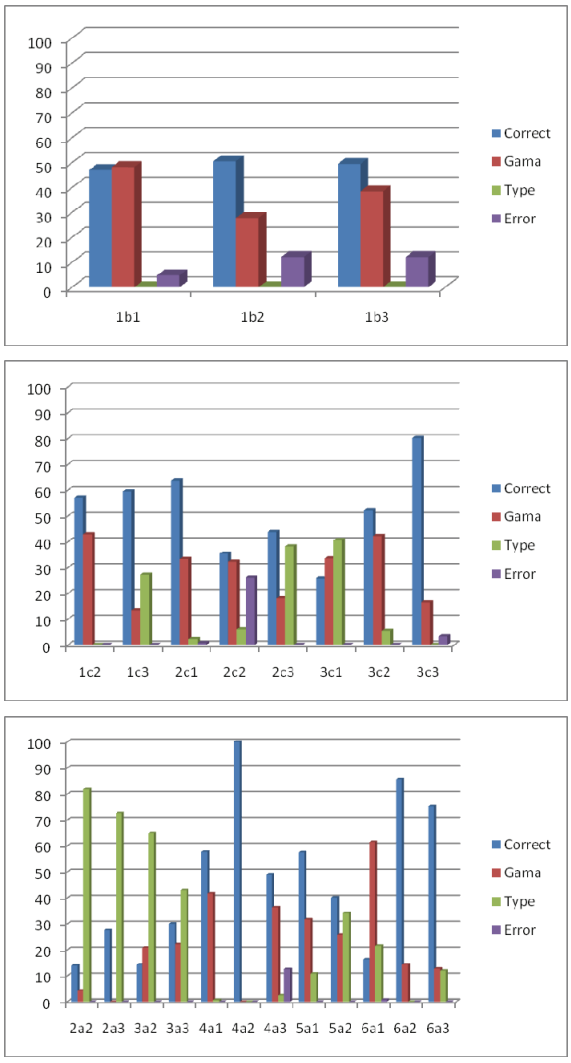

Figura 34 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=100 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades.

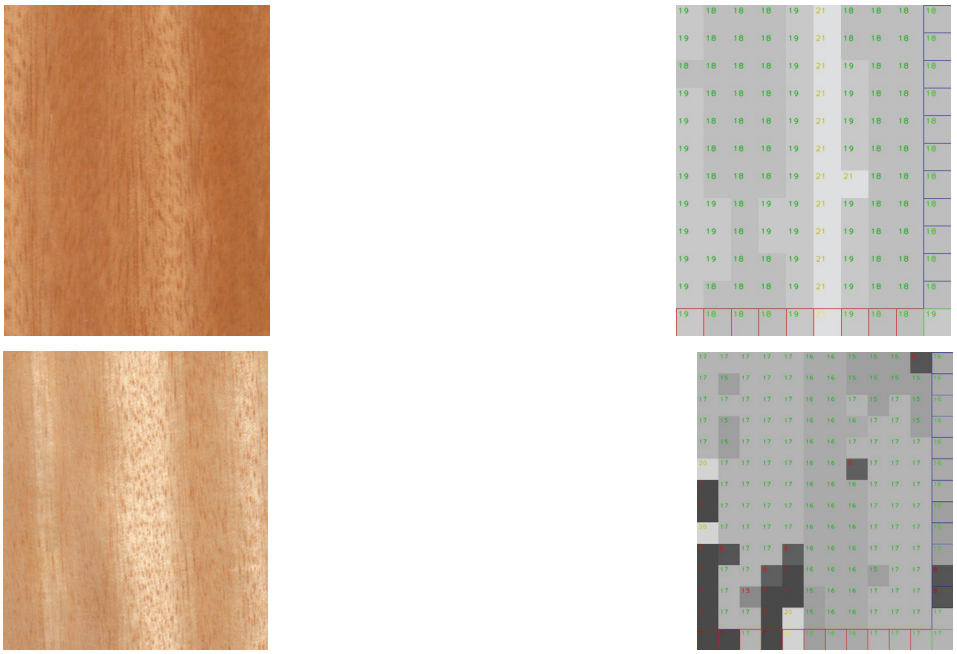

Figura 35 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 33.

Pretende-se agora estudar o método denominado de Auto/10 mais aprofundadamente e assim em vez de analisar apenas a taxa de erro, teve-se em conta também a correspondência por total, por tipo de madeira e tonalidade, e apenas por tipo. Os resultados apresentados pelos gráficos podem ser interpretados mais facilmente ao comparar as imagens fornecidas como exemplo das amostras e a respectivas imagens segmentadas. Isto porque consegue verificar-se com muita bastante facilidade a correspondência entre variações de tonalidade na imagem original, e as respectivas variações na imagem segmentada.

Comparando agora algumas das imagens segmentadas devolvidas como resultado da aplicação, pode verificar-se que o uso de uma janela reduzida pode ser útil para identificar variações de tonalidade em pequenas áreas, como pode ser verificado na Figura 35.

Note-se que a taxa de correspondência apenas com o mesmo tipo de madeira aumenta à medida que é fornecido um maior número de amostras para determinado tipo. Estes resultados levaram a uma comparação da percentagem de amostras de cada tipo com a percentagem de uma avaliação sem erro para cada tipo. Os resultados encontram-se expressos na Tabela V.

TABELA V

Resultados sem erro em qualquer das abordagens comparativamente ao número de amostras disponíveis para cada tipo de madeira

Tipo	Percentagem de amostras	Percentagem de Resultado Óptimo
A	52,174	30,435
B	13,043	0
C	37,783	13,043

Os resultados obtidos com uma janela de 200 pixéis (D=200), apresentados na Figura 36. Pretende-se verificar o impacto do aumento da janela na classificação das diferentes porções e na capacidade de detectar variações de tonalidade nas folhas de madeira identificadas com janelas de menor dimensão.

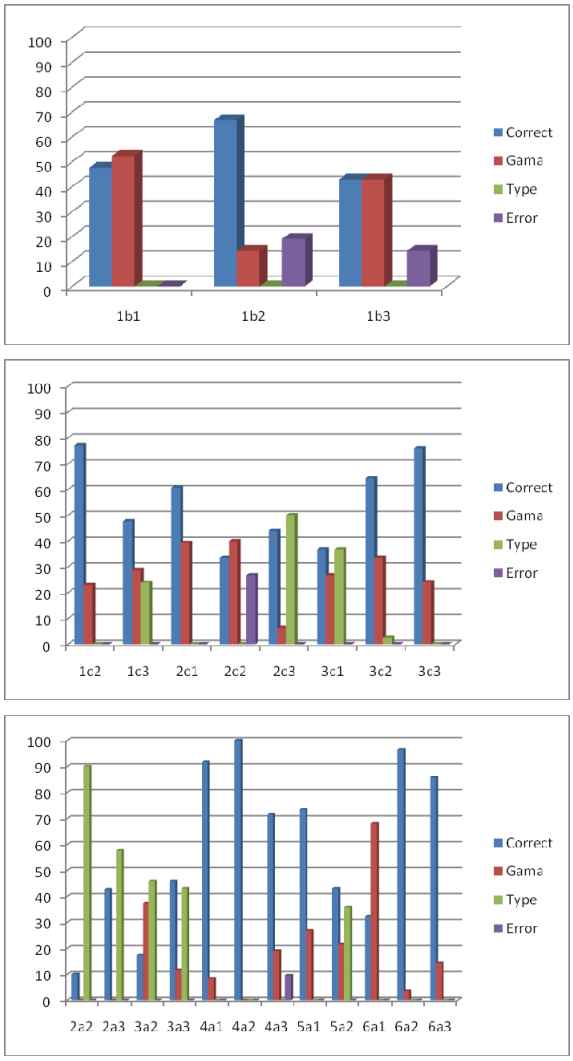

Figura 36 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=200 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades.

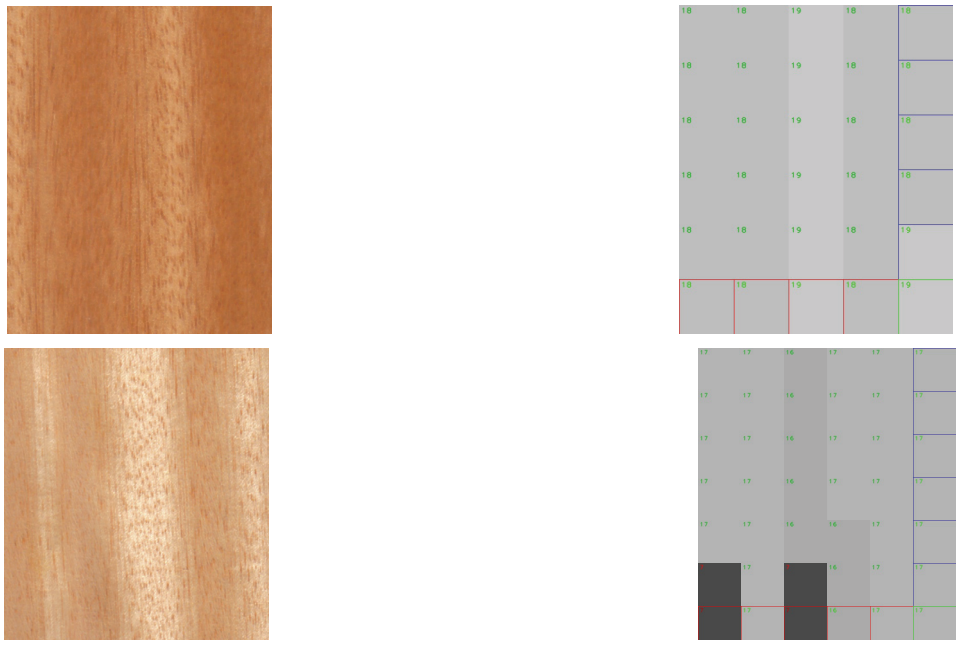

Figura 37 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 35.

Recorrendo novamente às amostras 5a1 e 4a3 pode verificar-se que a sensibilidade da aplicação diminuiu, no entanto continuando a diferenciar as variações de maior dimensão. As imagens resultantes da segmentação podem ser visualizadas na Figura 37. Ao comparar a imagem segmentada resultante da amostra 5a1 recorrendo a uma janela de 100 pixéis com a imagem obtida recorrendo a uma janela de 200 pixéis, é possível verificar claramente que, no caso da janela de menor dimensão, é visível o decaimento da tonalidade na “mancha” presente na amostra. Com o aumento da dimensão da janela continua a ser possível a detecção da referida “mancha”, no entanto esse decaimento já não é visível. Assim recorrendo a uma janela de 200 pixéis ainda é possível detectar variações de tonalidade com uma dimensão considerada significativa, no entanto, em casos que se verifiquem variações de dimensão considerada reduzida relativamente ao tamanho da janela, estas tenderão a ser absorvidas pela restante porção da imagem, podendo mesmo ser ignoradas.

Os resultados obtidos para uma janela de 400 pixéis (D=400) encontram-se representados na Figura 38. Note-se que recorrendo a janelas desta dimensão o número de porções a serem analisadas diminui bastante, dadas as dimensões das amostras em uso. Isso significa que uma porção que não seja identificada como pertencendo ao tipo de madeira a ser analisada, pode ser traduzida num aumento significativo da percentagem de erro, uma vez que cada porção apresenta um maior impacto no resultado final.

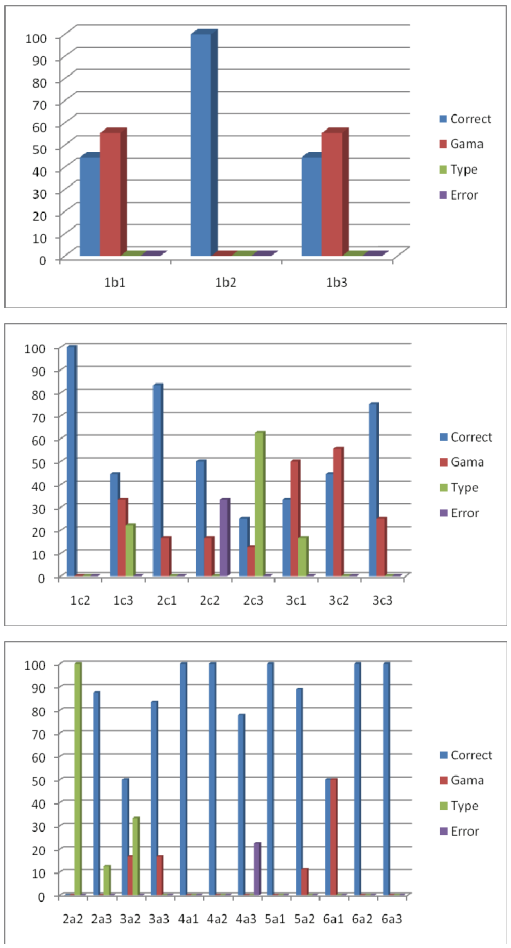

Figura 38 – Resultados para cada tipo de madeira obtidos recorrendo ao método Half-Step com D=400 e aproximações recorrendo a funções sino de apenas um parâmetro fixo e factor de divisão de 10 unidades.

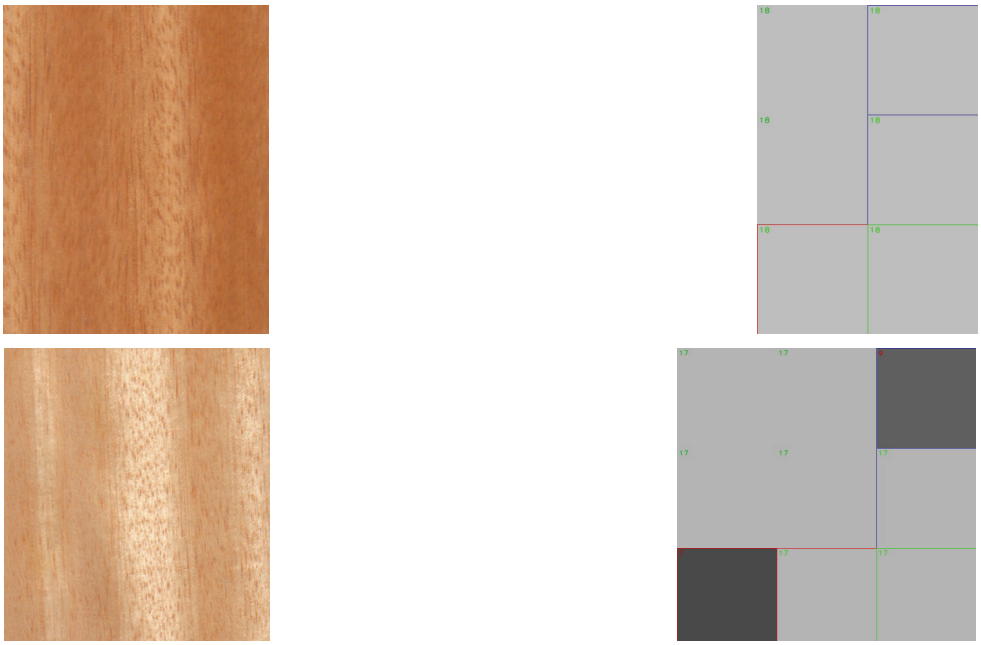

Figura 39 – Exemplo da amostra 5a1 e 4a3 e respectivas segmentações de acordo com as características referidas na Figura 38.

Como se pode constatar pela na Figura 39, a sensibilidade que se verificava com janelas de tamanho inferior diminui, sendo agora mais difícil de detectar pequenas variações. Apesar da taxa de erro ter diminuído bastante, algumas das amostras apresentam valores superiores aos pretendidos, nomeadamente 4a3 e 2c2, mas analisando a imagem segmentada resultante da amostra 4a3 verifica-se que essa percentagem corresponde apenas a uma porção.

Como referido anteriormente, os resultados acima apresentados foram obtidos recorrendo ao sistema de inferência Min-Max. No entanto depois de considerada a hipótese de um novo sistema de inferência, neste caso denominado de Sum-Max, procedeu-se a alguns testes para a ponderação do seu uso em trabalhos futuros. Alguns dos resultados obtidos para o sistema de inferência Sum-Max, com aproximações a funções sino de um parâmetro fixo e factor de divisão de 10 unidades recorrendo ao método Half-Step encontram-se apresentados em seguida.

TABELA VI

Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=100.

	Sum-Max	Min-Max
1b1	11,905	4,762
1b2	30	12,088
1b3	11,538	12,088
1c2	2,597	0
1c3	0	0
2c1	0	0,741
2c2	0	26,154
2c3	0	0
3c1	0	0
3c2	0,556	0
3c3	4,132	3,306
2a2	0	0
2a3	0	0
3a2	0	0
3a3	0	0
4a1	0	0
4a2	0	0
4a3	7,143	12,5
5a1	1,667	0
5a2	3,846	0

6a1	0	0,741
6a2	0	0
6a3	0	0

Como se pode verificar, à excepção de análises a madeira do tipo b, o sistema de inferência Sum-Max apresenta resultados considerados aceitáveis, uma vez que conseguiu trazer reduções à taxa de erro bastante significativas – redução máxima na ordem dos 26% - e nos casos em que se verificou um aumento do erro o valor apresentado não se verificava muito superior a resultados já obtidos – aumento máximo na ordem dos 4%.

TABELA VII

Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=200.

	Sum-Max	**Min-Max**
1b1	11,905	0
1b2	28,571	19,048
1b3	16,667	14,286
1c2	2,857	0
1c3	0	0
2c1	0	0
2c2	0	26,667
2c3	0	0
3c1	0	0
3c2	0	0
3c3	0	0
2a2	0	0
2a3	0	0
3a2	0	0
3a3	0	0
4a1	0	0
4a2	0	0
4a3	9,524	9,524
5a1	0	0
5a2	0	0
6a1	0	0
6a2	0	0
6a3	0	0

Mais uma vez, retirando os resultados relativamente a madeiras do tipo b – possivelmente devido ao défice de amostras deste tipo – verifica-se que os restantes apresentam valores bastante aceitáveis, tendo diminuido agora o aumento do erro para cerca de 3% e a diminuição do mesmo para em de 27%.

TABELA VIII

Resultados obtidos com o sistema de inferencia Sum-Max comparativamente ao Min-Max para com janelas de D=400.

	Sum-Max	Min-Max
1b1	11,111	0
1b2	22,222	0
1b3	11,111	0
1c2	0	0
1c3	0	0
2c1	0	0
2c2	0	33,333
2c3	0	0
3c1	0	0
3c2	0	0
3c3	0	0
2a2	0	0
2a3	0	0
3a2	0	0
3a3	0	0
4a1	0	0
4a2	0	0
4a3	11,111	22,222
5a1	0	0
5a2	0	0
6a1	0	0
6a2	0	0
6a3	0	0

Analisando agora as taxas de erro obtidas para uma janela de 400 pixéis, e se excluidos novamento os resultados obtidos para amostras do tipo b,verifica-se que o sistema de inferência Sum-Max apenas apresenta vantagens, pois para este caso não houve um aumento da taxa de erro relativamente ao sistema de inferencia Min-Max e a redução do erro aumentou para 33%, correspondendo este valor ao erro máximo

obtido para uma amostra recorrendo ao FMMIS, que apresenta uma taxa de erro nula quando submetida ao FSMIS.

4. Conclusões

Como se pode verificar através dos resultados apresentados a lógica difusa apresenta as características necessárias para a concretização deste projecto. Apresenta uma grande flexibilidade, tanto do ponto de vista da avaliação como facilidade no processo de treino. Recorrendo aos diferentes métodos de aproximação aos histogramas reais, ao ajuste dos diferentes parâmetros que os definem, número de amostras disponíveis e dimensão da janela utilizada durante o varrimento da imagem é possível alterar a sensibilidade do processo de avaliação. Assim consegue-se definir as variações de tonalidade que irão ser significativas no processo de avaliação, bem como a dimensão a ser considerada relevante.

Note-se que num aumento significativo das amostras pode ser necessário um reajuste dos parâmetros tidos em conta no processo de aproximação. No entanto é necessária uma cuidada selecção das amostras de modo a não inserir “dados” redundantes, ou seja, amostras em que as variações não sejam consideradas relevantes. Recomenda-se então no processo de selecção definir amostras que representem diferenças de tonalidade relevantes para cada tipo de amostra, e se possível definir “intervalos uniformes” de modo a tornar a fase de avaliação o mais rigorosa possível. Com isto pretende-se um número razoável de amostras, mas não exagerado, pois quanto maior o seu número, mais sensível é o processo de avaliação, por outro lado pode ser traduzido num aumento de processamento e possivelmente numa sobreposição de amostras. É também importante que a etiquetagem das amostras seja feita com rigor, garantindo assim uma percepção dos resultados mais intuitiva e evitando falsas ocorrências.

O ajuste de sensibilidade pode ser feito recorrendo também à variação da dimensão da janela usada no varrimento da imagem obtida. Quando essa dimensão é mais reduzida, uma pequena variação na textura ou tonalidade da porção de madeira a ser analisada representa um grande impacto em relação à totalidade da porção, no entanto, ao aumentar o tamanho da janela essa variação tende a ser “absorvida” pelo resto da imagem. Relativamente a aspectos que podem ser melhorados existe a possibilidade de implementação de uma “avaliação em cascata” caracterizada por dois

estágios. O primeiro, como já se encontrava a ser feito nas abordagens anteriores consiste numa avaliação global da imagem, devolvendo um determinado tipo de madeira, com determinada tonalidade e número de amostra. Note-se que nas etapas anteriores as características recolhidas encontravam-se todas armazenadas na mesma base de dados, e o que se pretende agora é implementar diversas bases de dados, ou seja, uma com as características de todas as amostras independentemente do tipo de madeira e as restantes com dados relativamente apenas a cada tipo de madeira. Assim a etapa seguinte consiste numa avaliação considerando apenas imagens do mesmo tipo de madeira para efectuar a correspondência das porções, obtendo-se assim uma segmentação baseada nas tonalidades apresentadas apenas para aquele tipo de madeira. É possível também acrescentar à aplicação um processo de treino durante a fase de avaliação. Ou seja, sempre que uma amostra apresente uma porção que não corresponda ao mesmo tipo de madeira devolvido pela avaliação global, esta seria adicionada como uma nova tonalidade para esse tipo de madeira. No entanto é preciso ter em conta que isto poderá fazer com que o número de amostras obtidas como treino aumentasse drasticamente, provocando um aumento do processamento. No pior dos casos poderá verificar-se uma sobreposição de amostras de diferentes tipos.

Poderá ser também implementada lógica difusa recorrendo a redes neuronais (da linguagem Anglo-Saxónica Neurofuzzy) [29] melhorando assim o processo de aproximação das funções pertença. Com este método as características extraídas do histograma de cada canal de uma imagem, ao serem submetidas aos diversos neurões presentes na rede irão resultar numa representação do histograma bastante mais precisa do que as obtidas recorrendo a funções sino.

Assim, de acordo com o referido, entende-se que a curto prazo será possível implementar o filtro em vários estágios, tendo em conta o tipo de madeira a ser analisado após o primeiro estágio e executar os testes necessários tanto com o sistema de inferência Min-Max como Sum-Max de modo a poder verificar se realmente o Sum-Max traz vantagens a todos os níveis.

É preciso também ter em conta que nos casos em que determinada porção de imagem a ser analisada devolve outro tipo de madeira como resultado, não significa mau funcionamento da aplicação. Isto acontece porque a amostra fornecida como treino que mais se aproxima da porção da imagem em análise corresponde a outro tipo de madeira, e que as amostras fornecidas para o tipo de madeira que se pretendia obter não abrangiam a situação referida. Nestes casos uma das soluções pode passar por repensar as amostras fornecidas como treino, verificando se será necessário

acrescentar amostras para os tipos que apresentem lacunas, ou recorrer a filtragem em cascata.

Bibliografia

[1] **http://clientes.netvisao.pt/alme0020/historia_madeiras.htm**
Pagina com uma perspectiva histórica e pequena abordagem aos processos de transformação de madeira. Data de utilização: 13.Setembro.2007

[2] Mário L. Roloff, Marcelo P. Adur, Uma Biblioteca de Processamento de Imagens para o Controle de Qualidade utilizando Dispositivos Portáteis (PDAs) em Sistemas Industriais de Visão.

[3] Dr. Richard Conners, Tai-Hoon Cho, Philip A. Araman, Automated Grading of Rough Hardwood Lumber, 3rd International Conference on Scanning Technology in Sawmilling, California 1989

[4] Matti Niskanen, A Visual Training Based Approach to Surface Inspection, Department of Electrical and Information Engineering, University of Oulu, Oulu 2003

[5] Gonzalo A. Ruz, Pablo A. Estévez, Claudio A. Perez, A Neurofuzzy Color Image Segmentation Method for Wood Surface Defect Detection, Department of Electrical Engineering, University of Chile, Santiago 2003

[6] Tai-Hoon Cho, Richard W. Conners, Philip A. Araman, A Computer Vision System For Analyzing Images Of Rough Hardwood Lumber, Blacksburg 1990

[7] Maria da Conceição R. Gaboleiro, Lógica Difusa – Temas Complementares em Investigação Operacional, Pós-Graduado em Matemática e suas aplicações, Investigação Operacional, FCT-UNL, Ano lectivo 2004/2005

[8] Marcílio C. P. de Souto, Lógicas para Inteligência Artificial.

[9] **http://www.handprint.com/HP/WCL/color7.html#CIELUV**
Pagina com a descrição de diversos modelos de cor elaborada por Bruce MacEvoy. Data de utilização: 25.Setembro.2007

[10] John C. Russ. The Image Processing Handbook, Third Edition.

[11] ColorLock™ da Silicon Graphics ,Guia do Usuário, Número do documento 007-3939-001PTB

[12] **http://en.wikipedia.org/wiki/RGB**
Explicação do espaço de cor RGB apresentada pela Wikipédia. Data de utilização: 25.Setembro.2007.

[13]
http://www.dpi.ufv.br/disciplinas/inf390/files/paginas/gbdi.icmc.sc.usp.br/documentacao/apostilas/cg/ap11.html

Página da disciplina de computação gráfica do Instituto de Ciências Matemáticas e de Computação, Departamento de Ciências de Computação e Estatística, referente a espaços de cor. Data de utilização: Maio.1999.

[14] **http://en.wikipedia.org/wiki/CIE_1931_color_space**

Explicação do espaço de cor CIE XYZ também conhecido como CIE 1931 apresentada pela Wikipédia. Data de utilização: 28.Agosto.2007.

[15] Bruno T. Moreira, Emídio A. A. Macedo. Mudanças de Coordenadas em Sistemas de Cores.

[16] **http://en.wikipedia.org/wiki/YCbCr**

Explicação do YCrCb apresentada pela Wikipédia. Data de utilização: 1.Setembro.2007.

[17] **http://local.wasp.uwa.edu.au/~pbourke/texture_colour/ycc/**

YCC Colour Space and Image Compression, por Paul Bourke. Breve abordagem ao YCrCb também conhecido como YCC, noções de compressão de imagem e algumas funções de conversão *standard* de espaços de cor. Data de utilização: Abril.2000.

[18] **http://en.wikipedia.org/wiki/HSV_color_space**

Explicação do espaço de cor HSV apresentada pela Wikipédia. Data de utilização: 16.Setembro.2007.

[19] **http://en.wikipedia.org/wiki/HSL_color_space**

Explicação do espaço de cor HSV apresentada pela Wikipédia. Data de utilização: 16.Setembro.2007.

[20] Dan Margulis. Photoshop Lab Color: The Canyon Conundrum and Other Adventures in the Most Powerful Colorspace, ISBN 0321356780.

[21] Fred W. Billmeyer, Max Saltzman, Principles of color technology, 2ed: John Wiley & Sons, 1981.

[22] Alexander Poularikas, Digital Color Imaging Handbook, CRC Press, 2003.

[23] **http://en.wikipedia.org/wiki/Lab_color_space**

Explicação do espaço de cor L*a*b* apresentada pela Wikipédia. Data de utilização: 16.Setembro.2007.

[24] **http://en.wikipedia.org/wiki/CIELUV_color_space**

Explicação do espaço de cor L*u*v* apresentada pela Wikipédia. Data de utilização: 16.Agosto.2007.

[25] **http://hydra.nac.uci.edu/~wiedeman/cspace/me/infoluv.html**

Explicação do espaço de cor L*u*v* apresentado pela Network and Academic Computing Services da Universidade da California. Data de utilização: 27.September.2007*.

[26] Manuel João O. Ferreira, “Desenvolvimento de um Protótipo para a Identificação, Classificação e Quantificação de Defeitos, Aplicável em Ambiente Industrial”,Tese de Doutoramento, Universidade do Minho, 2004

[27] Teresa Maria F. Valente, “Modelos de caracterização de impacte ambiental para escombreiras reactivas : equilíbrio e evolução de resíduos de actividade extractiva”, Tese de Doutoramento, Universidade do Minho, 2004

[28] **http://opencvlibrary.sourceforge.net/CvReference**
CV Reference Manual disponibilizado pela sourceforge. Data de utilização: 01.Outubro.2007.
[29] J. R. Jang, C. T. Sun, E. Mizutani, Neuro-fuzzy and soft computing, a computational approach to learning and machine intelligence: Prentice-Hall, 1997.
[30] Manuel J. Ferreira, Cristina P. Santos, Tracking system using texture cue based on wavelet transform.
[31] Cristina M. Peixoto Santos, Manuel João Ferreira,Control of an Industrial Desktop Robot Using Computer Vision and Fuzzy Rules

Referências Gráficas

Figura 2.a – Modificada de:
http://www.mathworks.com/access/helpdesk/help/toolbox/images/color7.gif

Figura 2.b – Modificada de:
http://upload.wikimedia.org/wikipedia/commons/thumb/e/e0/Synthese%2B.svg/200px-Synthese%2B.svg.png

Figura 3 – Modificada de:
http://upload.wikimedia.org/wikipedia/commons/thumb/0/02/CIExy1931.svg/326px-CIExy1931.svg.png

Figura 4.a – Modificada de:
http://upload.wikimedia.org/wikipedia/en/thumb/e/ea/HSV_cone.png/250px-HSV_cone.png

Figura 4.b – Modificada de:
http://upload.wikimedia.org/wikipedia/commons/thumb/a/ad/HueScale.svg/250px-HueScale.svg.png

Figura 5 – Modificada de:
http://en.wikipedia.org/wiki/HSL_color_space

Figura 6 – Modificada de:
http://www.newsandtech.com/issues/2002/02-02/ifra/images/42Lab.jpg

Figura 1240 – Modificada de:
Teresa Maria F. Valente, “Modelos de caracterização de impacte ambiental para escombreiras reactivas : equilíbrio e evolução de resíduos de actividade extractiva”, Tese de Doutoramento, Universidade do Minho, 2004

Figura 21 – Modificada de:

Teresa Maria F. Valente, “Modelos de caracterização de impacte ambiental para escombreiras reactivas : equilíbrio e evolução de resíduos de actividade extractiva”, Tese de Doutoramento, Universidade do Minho, 2004

Lista de Siglas e Acrónimos

SOM Self-Organizing Maps, também conhecidos como *Kohonen´s Maps*

FMMIS Sistema de inferência de lógica Difusa Min-Max (da linguagem Anglo-Saxónica Fuzzy Min-Max Inference System)

FSMIS Sistema de inferência de lógica Difusa Sum-Max (da linguagem Anglo-Saxónica Fuzzy Sum-Max Inference System)

Anexos

I. Anexo 1 – Amostras de folha de madeira disponíveis.

2a2

2a3

3a2

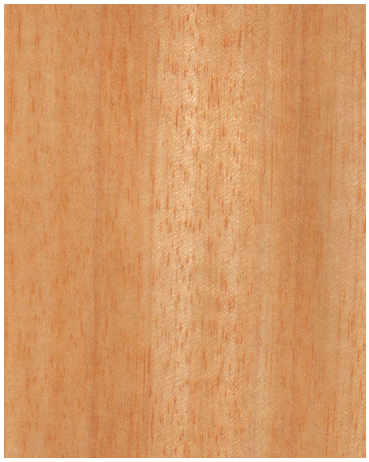

3a3

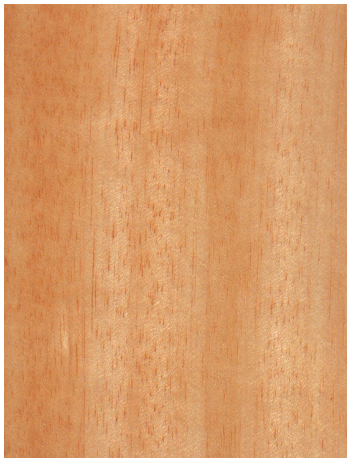

4a1

4a2

4a3

5a1

5a2

6a1

6a2

6a3

1b1

1b2

1b3

1c2

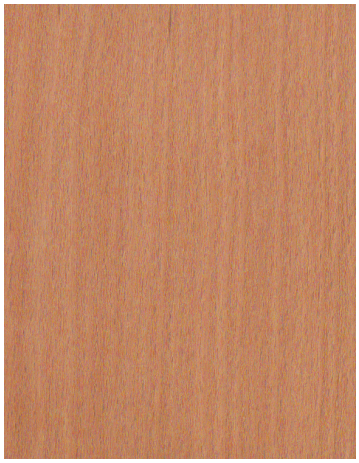

1c3

2c1

2c2

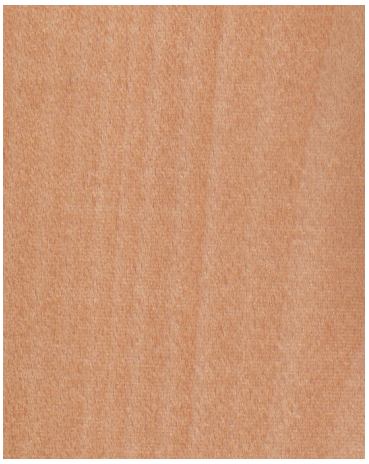

2c3